

Methoden zur Analyse von Garantiedaten  
für die Sicherheits- und Zuverlässigkeitsprognose  
von Komponenten und Baugruppen im Kraftfahrzeug

Vom Fachbereich Sicherheitstechnik  
der Bergischen Universität Wuppertal  
zur Erlangung des akademischen Grades

-Doktor-Ingenieur-  
genehmigte Dissertation

von  
Dipl.-Ing. Matthias Meyer  
aus Kandel

Gutachter:  
Univ.-Prof. Dr.-Ing. A. Meyna  
Univ.-Prof. Dr.-Ing. O. H. Peters

Tag der mündlichen Prüfung:  
17.09.2003

D 468



*Für meine Eltern*

# Danksagung

Die vorliegende Arbeit entstand während meiner Tätigkeit als wissenschaftlicher Mitarbeiter an der Bergischen Universität im Fachgebiet Sicherheitstheorie und Verkehrstechnik bei der Bearbeitung des von der Deutschen Forschungsgemeinschaft (DFG) geförderten Projektes „Zuverlässigkeitsprognosen für Komponenten und Baugruppen im Kraftfahrzeug“.

Mein ganz besonderer Dank gilt meinem Doktorvater Herrn Univ.-Prof. Dr.-Ing. A. Meyna für die hervorragende Betreuung und Unterstützung, die weit über den Rahmen dieser Arbeit hinaus ging.

Univ.-Prof. Dr.-Ing. O. H. Peters, Prof. Dr.-Ing. P. Winzer und Univ.-Prof. Dr. rer. nat. P. C. Müller danke ich für die Erstellung des zweiten Gutachtens und ihre Mitwirkung im Promotionsausschuss.

Des weiteren möchte ich allen Kollegen für den regen Gedankenaustausch und die praktischen Ratschläge, insbesondere Dipl.-Ing. Jan Hauschild für seine Unterstützung bei statistischen Fragen, danken.

Für die Bereitstellung der notwendigen Daten und die weitreichende Unterstützung gilt mein Dank der Robert Bosch GmbH. Insbesondere möchte ich mich bei Herrn Dipl.-Ing. (FH) P. Grodzicki und Herrn Dipl.-Phys. N. Wasmer für die fachlichen und praktischen Anregungen bedanken. Mein besonderer Dank gilt auch Herrn Dr.-Ing. B. Pauli für seine kritischen Anregungen, die wesentlich zum Gelingen dieser Arbeit beigetragen haben.

Ohne den Rückhalt und das Vertrauen meiner Familie und die Unterstützung meiner Frau wäre diese Arbeit nicht möglich gewesen. Ihnen möchte ich daher in ganz besonderem Maße danken.

# Kurzfassung

Der zunehmende Anteil hochintegrierter, vernetzter Systeme im Kraftfahrzeug macht es immer wichtiger, frühzeitig sicherheits- und zuverlässigkeitstechnische Analysen durchzuführen. Grundlage quantitativer Risikobewertungen ist die Ermittlung sicherheits- und zuverlässigkeitstheoretischer Kenngrößen. In dieser Arbeit werden neue praxisgerechte und generalisierte Zuverlässigkeitsprognosemodelle zur Analyse des Ausfallverhaltens von Kfz-Komponenten und Baugruppen entwickelt. Grundlage der Modelle ist ein allgemeines Ausfallmodell, das es nunmehr ermöglicht, beliebiges Ausfallverhalten zu beschreiben und den gesamten Verlauf der Ausfallrate, die sog. „Badewannenkurve“, in die Zuverlässigkeitsprognose zu integrieren. Mit Hilfe der entwickelten Modelle lässt sich schon frühzeitig das Feldausfallverhalten der Kfz-Systeme abschätzen und entsprechende Kenngrößen ermitteln. Die gewonnenen Ergebnisse können unterstützend in betriebliche Entscheidungsprozesse integriert und als Feld-Feedback-Information für die Entwicklung und Bewertung neuer Systeme genutzt werden. Die Prognosemodelle schließen somit den Regelkreis der Produktentwicklung. Des Weiteren lassen sich auch die zu erwartenden Garantiekosten, der Serienersatzbedarf sowie die Endbevorratungsmenge prognostizieren.

Garantiedaten sind häufig die einzig gesicherte Information über das reale Ausfallverhalten von Produkten im Feld. Bei frühzeitigen Prognosen sind diese Daten jedoch häufig unvollständig und enthalten noch nicht alle Informationen über das tatsächliche Ausfallverhalten. Gründe hierfür sind beispielsweise der Zulassungs- und Meldeverzug. In dieser Arbeit werden neue Ansätze entwickelt, die solche Einflüsse berücksichtigen und in die Zuverlässigkeitsprognose integrieren.

Die Zuverlässigkeit von Komponenten und Baugruppen wird in der Praxis oft von weiteren externen Faktoren, wie der Temperatur, der Feuchte oder sonstigen Umgebungsparametern beeinflusst. Meist lassen sich solche Faktoren jedoch nur schwer quantitativ erfassen und deren Wirkungsweise nur unzureichend funktional beschreiben. In dieser Arbeit wird ein neues erweitertes neuronales Zuverlässigkeitsprognosemodell entwickelt, das beliebige Einflüsse auf das Ausfallverhalten erlernen und entsprechend modellieren kann. Mit Hilfe des erweiterten neuronalen Modells ist es möglich, das Ausfallverhalten bzw. die Zuverlässigkeit von Komponenten und Baugruppen in Kraftfahrzeugen bei sich ändernden Umgebungsbedingungen zu prognostizieren. Der neue neuronale Ansatz zur Beschreibung zusätzlicher Einflussfaktoren auf die Zuverlässigkeit stellt eine erhebliche Erweiterung der entwickelten Prognosemodelle dar.

## Abstract

The increasing portion of highly integrated and networked systems in motor vehicles makes it ever more important to conduct safety and reliability analyses as early as possible. Basis of the quantitative risk assessment are the safety and reliability characteristics. In this dissertation new practicable and generalized reliability prognosis models for analysing the failure behaviour of automotive components and devices are developed. Basis of the prognosis model is a generalized failure model, that makes it now possible to describe arbitrary failure behaviour and integrates the entire failure rate, the so-called “bath-tub-curve”, into the reliability prognosis model. Applying these models, early predictions of the field failure behaviour of the automotive systems are possible and the appropriate characteristics can be determined. The results of the analyses can be integrated in the decision processes and can also be used as field feedback information for the development of new systems. Thus, the prognosis models close the loop of the product development process. Additionally the guarantee costs and the amount of serial spare parts and final stockings can be predicted.

Often guarantee data provide the only assured information about the product field performance. For early predictions, these data however contain only incomplete information about the real failure behaviour due to registration and reporting delays. Therefore new models are developed to consider these influences.

In practice the reliability of components and devices is influenced by further external factors, such as temperature, humidity or other environmental parameters. Usually the determination of these factors is difficult and their functional impact can only insufficiently be described. In this project report a new extended neural reliability prediction model is developed, which can learn and model arbitrary influences on the failure behaviour. Using the neural network the failure behaviour respectively the reliability of components and devices of motor vehicles can be predicted in case of changing environmental and using conditions. The new neural approach to model the external influences on the reliability of automotive systems represents a substantial extension of the developed prognosis models.

# Inhaltsverzeichnis

<b>1</b>	<b>EINLEITUNG</b>	<b>11</b>
<b>2</b>	<b>GRUNDLAGEN</b>	<b>19</b>
<b>2.1</b>	<b>Statistik</b>	<b>19</b>
2.1.1	Grundgesamtheit und Stichprobe	19
2.1.2	Parameterschätzung	20
2.1.3	Konfidenzintervalle	22
<b>2.2</b>	<b>Zuverlässigkeitstheorie</b>	<b>23</b>
2.2.1	Theoretische Zuverlässigkeitskenngrößen	23
2.2.2	Empirische Zuverlässigkeitskenngrößen	25
2.2.3	Verteilungsfunktionen	27
<b>2.3</b>	<b>Neuronale Netze</b>	<b>28</b>
2.3.1	Biologisches Vorbild	29
2.3.2	Geschichte Neuronaler Netze	30
2.3.3	Theorie Künstlicher Neuronaler Netze	31
2.3.4	Arten Neuronaler Netze	36
<b>3</b>	<b>UNTERSUCHTE SYSTEME</b>	<b>38</b>
<b>3.1</b>	<b>Wischesysteme</b>	<b>39</b>
<b>3.2</b>	<b>Kupplungsteller</b>	<b>42</b>
<b>3.3</b>	<b>Motorkühlgebläse</b>	<b>43</b>
<b>4</b>	<b>ALLGEMEINES ZUVERLÄSSIGKEITSPROGNOSEMODELL</b>	<b>45</b>
<b>4.1</b>	<b>Ausfallmodelle</b>	<b>45</b>
4.1.1	Unimodales Ausfallmodell	45
4.1.2	Mischpopulations-Ausfallmodell	46
4.1.3	Konkurrierendes Ausfallmodell	47
4.1.4	Teilpopulations-Ausfallmodell	48
4.1.5	Verallgemeinertes Ausfallmodell	49
4.1.6	Badewannenmodelle	51

---

<b>4.2</b>	<b>Ablauf einer allgemeinen Zuverlässigkeitsprognose</b>	<b>54</b>
4.2.1	Voraussetzungen	55
4.2.2	Vorhandene Datenstruktur	55
4.2.3	Bestimmung der Fahrleistungsverteilung	56
4.2.4	Entwicklung des Ausfallmodells	58
4.2.5	Bestimmung der km-abhängigen Zuverlässigkeitskenngrößen	62
4.2.6	Bestimmung der zeitabhängigen Zuverlässigkeitskenngrößen	65
<b>4.3</b>	<b>Ergebnisse</b>	<b>67</b>
4.3.1	Wischermotoren	67
4.3.2	Kupplungsteller	73
4.3.3	Steuergeräte für Motorkühlgebläse	80
4.3.4	Weitere Nutzungsmöglichkeiten der Prognoseergebnisse	88
<b>5</b>	<b>EIN NEUES ZUVERLÄSSIGKEITSPROGNOSEMODELL FÜR UNVOLLSTÄNDIGE DATEN</b>	<b>93</b>
<b>5.1</b>	<b>Einflussfaktoren</b>	<b>94</b>
5.1.1	Zulassungsverzug	94
5.1.2	Meldeverzug	95
5.1.3	Korrigierte Anwärterberechnung	96
<b>5.2</b>	<b>Modifiziertes Prognosemodell</b>	<b>97</b>
<b>5.3</b>	<b>Ergebnisse</b>	<b>98</b>
5.3.1	Simulation	98
5.3.2	Felddaten	100
<b>6</b>	<b>ERWEITERTES NEURONALES ZUVERLÄSSIGKEITSPROGNOSEMODELL</b>	<b>103</b>
<b>6.1</b>	<b>Statistischer Ansatz</b>	<b>103</b>
6.1.1	Generalisiertes Lineares Regressionsmodell	103
6.1.2	Spezielle Regressionsmodelle	104
<b>6.2</b>	<b>Neuronaler Ansatz</b>	<b>107</b>
6.2.1	Datentransformation	109
6.2.2	Netzarchitektur	110
6.2.3	Lernverfahren	113



---

6.2.4	Gütemaße	115
<b>6.3</b>	<b>Verwendete Daten</b>	<b>116</b>
6.3.1	Klimadaten	116
6.3.2	Garantiedaten	117
<b>6.4</b>	<b>Ermittelte Einflussgrößen</b>	<b>118</b>
<b>6.5</b>	<b>Entwicklung eines neuronalen Zuverlässigkeitsprognosemodells</b>	<b>120</b>
6.5.1	Datenanalyse und Datenaufbereitung	120
6.5.2	Netzarchitektur	122
6.5.3	Versuchsplan	124
<b>6.6</b>	<b>Ergebnisse</b>	<b>125</b>
<b>7</b>	<b>ZUSAMMENFASSUNG UND AUSBLICK</b>	<b>134</b>
<b>8</b>	<b>LITERATUR</b>	<b>137</b>
<b>A</b>	<b>ANHANG</b>	<b>144</b>
<b>A.1</b>	<b>Verwendete Symbole</b>	<b>144</b>
<b>A.2</b>	<b>Statistische Ergebnisse</b>	<b>148</b>
A.2.1	Untersuchte Systeme	148
A.2.2	Simulation zeitnaher Daten	155
<b>A.3</b>	<b>Neuronale Netze</b>	<b>158</b>
A.3.1	Datensatz 1	159
A.3.2	Datensatz 2	191




# 1 Einleitung

Schnelle Fortschritte in der Technologie, die Entwicklung von anspruchsvollen komplexen Produkten, der verstärkte globale Konkurrenzkampf und zunehmende Erwartungen von Kunden erhöhen die Anforderungen an die Hersteller, hoch zuverlässige Produkte herzustellen. Die Kunden erwarten beim Kauf eines Produktes, dass diese sicher und zuverlässig funktionieren, d.h. die Erzeugnisse sollen mit hoher Zuverlässigkeit die gewünschte Funktion unter normalen Einsatzbedingungen für eine vorgegebene Zeit erfüllen und zu keiner Zeit eine Gefährdung darstellen. Die Sicherheit von Produkten ist eng mit dem Begriff des Risikos verknüpft. Dieses lässt sich wie folgt definieren:

$$\text{Risiko} = \text{Fehlerwahrscheinlichkeit} \cdot \text{Fehlerschwere} .$$

Zur Abschätzung der potentiellen Risiken eines Produktes ist es notwendig, die Auftretenswahrscheinlichkeit für ein unerwünschtes Ereignis zu ermitteln und die Auswirkungen eines solchen Ereignisses zu bewerten. Das so ermittelte Risikomaß ist dann von den Verantwortlichen mit einem zuvor festgelegten maximal akzeptierbaren Grenzrisiko zu vergleichen, um gegebenenfalls Maßnahmen zur Risikoreduktion zu ergreifen. Die Risikoakzeptanz des Kunden oder der Öffentlichkeit ist für verschiedene Ereignisse mit vermeintlich gleichem Risiko jedoch nicht immer identisch. Dies wird vor allem bei sehr schweren Fehlerfolgen deutlich, die dann oft wesentlich stärker gewichtet werden als die zugehörigen Fehlerwahrscheinlichkeiten. Des Weiteren stellt auch der Gesetzgeber Anforderungen hinsichtlich der Sicherheit und Zuverlässigkeit von Produkten. So besteht für den Hersteller die Produkthaftung und die Pflicht der Produktbeobachtung, die ein Bestandteil der Verkehrssicherungspflicht ist. Diese verpflichtet den Hersteller in Verkehr gebrachte Produkte über deren gesamte Lebensdauer zu beobachten. Nicht zuletzt bestehen auch Ansprüche des Kunden bezüglich der Sicherheit und Zuverlässigkeit der erworbenen Produkte, die oft auch Bestandteil des Kaufvertrages sind. Das folgende Bild 1.1 zeigt die Entwicklung der Rückrufaktionen in Deutschland von den Jahren 1992 bis 2002. Die Anzahl der Rückrufaktionen, durch Unterstützung des Kraftfahrt-Bundesamtes (KBA), blieb bis 1997 nahezu konstant und ist in den letzten Jahren stetig gestiegen. Ein Grund hierfür kann nach KBA das im Jahr 1997 in Kraft getretene Produktsicherheitsgesetz (ProdSG) sein. Seitdem stieg die Zahl der Rückrufe um 119 Prozent an. Diese Entwicklung zeigt, wie wichtig es ist, frühzeitig sicherheits- und zu-

verlässigkeitstechnische Betrachtungen durchzuführen, um schon in frühen Entwicklungsphasen Probleme und Risiken zu erkennen und Maßnahmen ergreifen zu können.

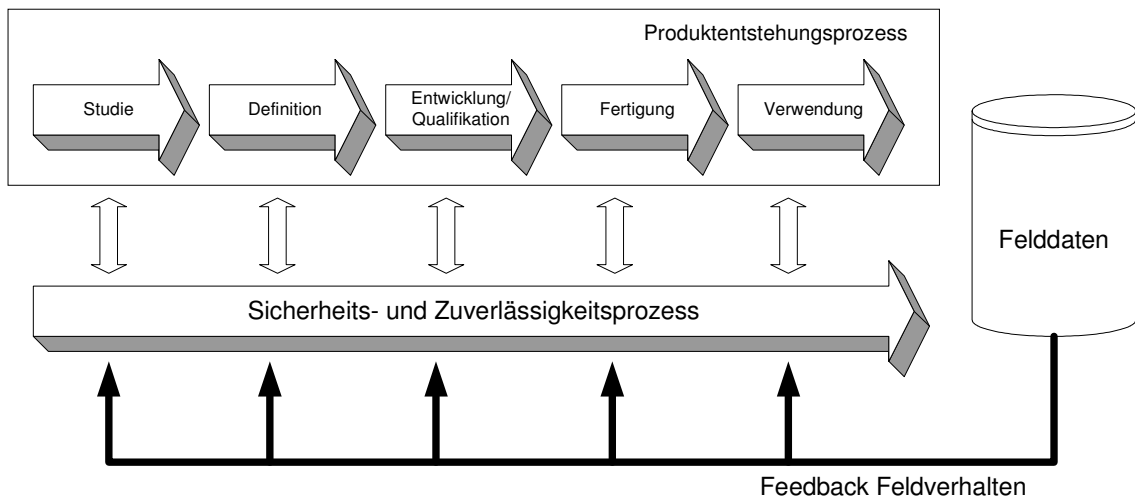


**Bild 1.1:** Entwicklung der Rückrufaktionen in Deutschland von 1992 bis 2002 [KBA03]

Zur Erfüllung der gesetzten Ziele ist es daher notwendig, ein prozessorientiertes Sicherheits- und Zuverlässigkeitsmanagement zu errichten. Dieses soll die notwendigen Aktivitäten begleitend zum Produktentstehungsprozess koordinieren und so die Sicherheit und Zuverlässigkeit von Produkten definieren, planen, integrieren und verifizieren. Detaillierte Erläuterungen zu Sicherheits- und Zuverlässigkeitsmanagement findet man u.a. in [Mey03].

Ein wesentlicher Bestandteil eines solchen Sicherheits- und Zuverlässigkeitsprozesses ist die Felddatenauswertung. Diese ermöglicht es, Erfahrungen über die bestehenden Produkte qualitativ und quantitativ zu ermitteln, aufzubereiten und in den Produktentstehungsprozess wieder einfließen zu lassen. Bild 1.2 zeigt schematisch den Informationsfluss und die Prozesse während der Produktentstehung und -verwendung. Die gewonnenen Feldinformationen können im Sicherheits- und Zuverlässigkeitsprozess u.a. für die Ermittlung von Schwachstellen, des zeitabhängigen Ausfallverhaltens und der tatsächlichen Belastung und Beanspruchung der Produkte im Feld genutzt werden. Mit Hilfe der Feld-Feedback-Informationen lassen sich des Weiteren auch die vorhandenen Testeinrichtungen und -verfahren überprüfen und gegebenenfalls optimieren. Die Feld-

datenanalyse ist somit ein wichtiger Bestandteil präventiver Maßnahmen zur Gewährleistung der Sicherheit und Zuverlässigkeit von Produkten.



**Bild 1.2: Prozesse und Informationsfluss in der Produktentstehung und -verwendung**

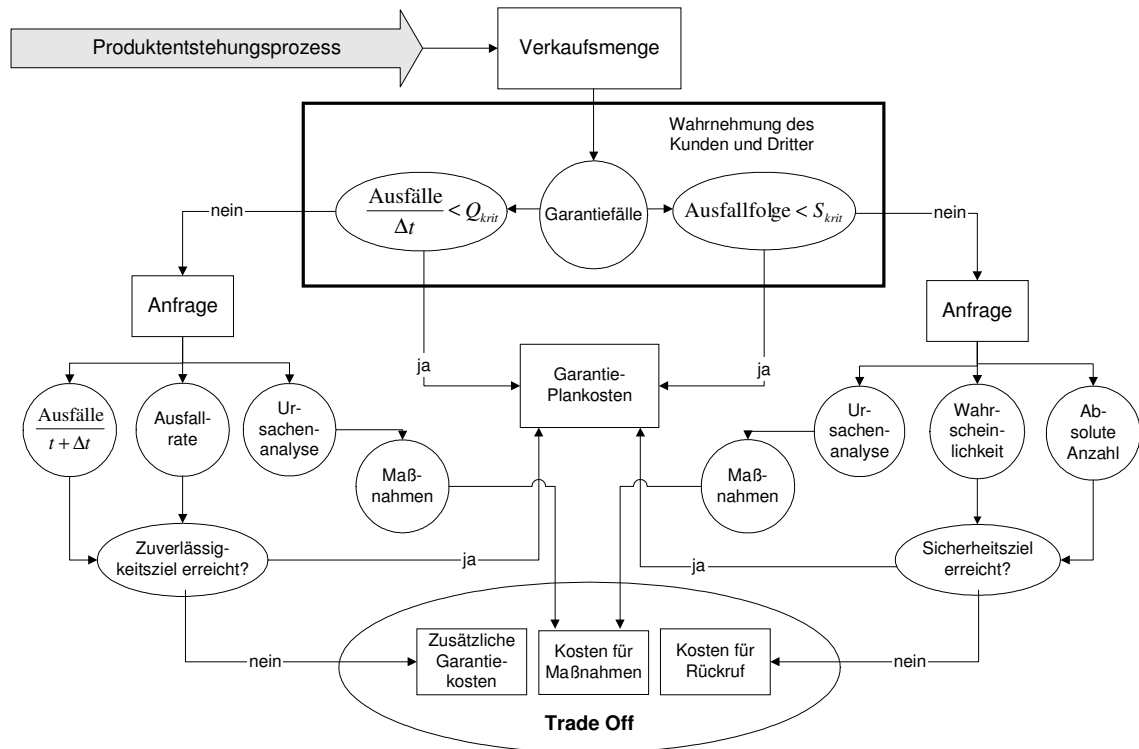
Für die Analyse des Feldverhaltens stehen meist nur Daten aus der Garantiezeit, die sich vorwiegend auf 1 bis 2 Jahre beschränkt, zur Verfügung. Im Automobilbereich gehen die Bestrebungen jedoch dahin, die Garantiezeiten erheblich zu erweitern, so dass auch Garantieansprüche nach 3 bis 6 Jahren noch geltend gemacht werden können. Dies führt zu einer wesentlich größeren Datenbasis für zukünftige statistische Betrachtungen, bedeutet zum anderen jedoch auch zunehmende Kosten für den Hersteller. Es wird daher immer wichtiger, das zeitliche Ausfallverhalten von Produkten frühzeitig zu prognostizieren, insbesondere in Übergangsphasen, in denen noch wenig Felddaten zu betroffenen Produkten vorhanden sind. Ein wesentlicher Vorteil der Garantiedaten für die Felddatenanalyse ist deren fast kostenlose Verfügbarkeit, da in vielen Unternehmen die Garantiefälle bereits für betriebswirtschaftliche Belange erfasst und entsprechend in Datenbanken gespeichert werden. Eine separate Datenerhebung ist daher meist nicht erforderlich.

Um die vorhandenen Daten sinnvoll nutzen zu können, ist es notwendig, Verfahren und Methoden zu entwickeln, die es ermöglichen, die Zuverlässigkeit von Produkten schon möglichst frühzeitig zu prognostizieren. Für die Analyse von Garantiedaten wurden in den letzten Jahren einige Ansätze entwickelt. Suzuki untersuchte das Felddatenverhalten bei zensierten Daten [Suz85a] und verwendete parameterfreie Verfahren für die Analyse [Suz85b]. Kalbfleisch und Lawless entwickelten in [Kal88] ein Modell zur Berücksichtigung von Kovariablen. Eine Zusammenfassung weiterer Ansätze findet man u.a. in [Law98]. Pauli und Meyna entwickelten eine alternative Vorgehensweise

zur Analyse zensierter Felddaten [Pau00]. Dieses mehrstufige Prognosemodell bildet, auf Grund der großen Praxisrelevanz, vor allem für Großserienprodukte, die Grundlage dieser Arbeit.

Ein Ziel dieser Arbeit ist es, ein neues allgemeines Zuverlässigkeitsprognosemodell zu entwickeln, das es ermöglicht, beliebige Systeme, Baugruppen und Komponenten mit beliebigem Ausfallverhalten zu analysieren. Die praktische Anwendbarkeit des entwickelten allgemeinen Zuverlässigkeitsprognosemodells soll durch die beispielhafte Analyse von mechanischen, elektronischen und mechatronischen Systemen nachgewiesen werden, wobei das Ausfallverhalten der ausgewählten Systeme modelliert und deren Zuverlässigkeit im Felde prognostiziert wird.

Die mit Hilfe des allgemeinen Zuverlässigkeitsprognosemodells ermittelten theoretischen Wahrscheinlichkeitsfunktionen beschreiben zum einen das Ausfallverhalten der Produkte während der Garantiezeit und erlauben zum anderen auch Aussagen über das zu erwartende zukünftige Verhalten der Erzeugnisse im Feld. Dies ist besonders gegenüber Kundenforderungen wichtig, wenn Schätzungen über die noch zu erwartenden Ausfälle für einen bestimmten Zeitraum zu machen sind. Damit es zu solchen Anfragen des Kunden oder sonstigen Dritten kommt, muss die Anzahl der beobachteten Garantiefälle, die innerhalb eines Zeitraums  $\Delta t$  auftreten, eine kritische Grenze überschreiten. Ist dies der Fall, werden weitere Aktivitäten notwendig, die u. U. zu zusätzlichen Kosten führen. Des Weiteren werden bei Ausfällen mit schweren Fehlerfolgen Abschätzungen des Risikos erforderlich. Liegt die Fehlerfolge oberhalb einer kritischen Grenze, muss zusätzlich zur Auftretenswahrscheinlichkeit auch die absolute Anzahl der noch zu erwartenden Ausfälle mit gleicher Fehlerfolge prognostiziert werden. Bild 1.3 zeigt allgemein den Ablauf einer Anfrage zur Prognose des Feldausfallverhaltens von beliebigen Produkten.



**Bild 1.3: Anfrage Prognose des Feldausfallverhaltens**

Nach einem Vergleich der Prognoseergebnisse mit den Sicherheits- und Zuverlässigkeitszielen muss gegebenenfalls über weitere Maßnahmen oder einen möglichen Rückruf der betroffenen Produkte entschieden werden. Das Zuverlässigkeitsprognosemodell stellt somit ein wichtiges Werkzeug innerhalb der betrieblichen Entscheidungsprozesse dar.

Zum besseren Verständnis der Arbeit werden in Kapitel 2 die grundlegenden statistischen Verfahren eingeführt und die Theorie der Neuronalen Netze kurz beschrieben. Es wird des Weiteren ein Überblick zu den wichtigsten Begriffen und Definitionen der Zuverlässigkeitstheorie gegeben.

Der Anteil komplexer, vernetzter Systeme im Kraftfahrzeug nimmt stetig zu. Die im Rahmen dieser Arbeit analysierten Komponenten und Baugruppen werden in Kapitel 3 kurz beschrieben. Es wird außerdem ein Überblick zu aktuellen und zukünftigen Entwicklungen im Automobilbau gegeben. Die betrachteten Systeme wurden beispielhaft ausgewählt, um einen möglichst breiten Querschnitt von Systemen im Kraftfahrzeug zu zeigen. Zukünftige Systeme zeichnen sich durch eine eigene Aktuatorik und Steuerung bei einer hochintegrierten Bauweise aus. Im Rahmen der Arbeit werden verschiedene Elektromotoren, Steuergeräte und komplexe Aktuatoren analysiert und deren Zuverlässigkeit prognostiziert.

Um beliebige Komponenten und Baugruppen im Kraftfahrzeug analysieren zu können, wird in Kapitel 4 ein neues allgemeines Ausfallmodell entwickelt. Mit Hilfe dieses Ausfallmodells ist es möglich, beliebige Fehler- und Ausfallmechanismen zu modellieren. So können nun auch komplexe Zusammenhänge zwischen den Ausfallwahrscheinlichkeiten von Subsystemen genau abgebildet und in die Prognose integriert werden. Das allgemeine Ausfallmodell bildet die Grundlage des entwickelten generalisierten Zuverlässigkeitsprognosemodells. In dem Kapitel wird des Weiteren die Vorgehensweise und die Struktur der allgemeinen Zuverlässigkeitsprognose auf Basis von Felddaten erläutert. Die praktische Anwendbarkeit des Modells wird durch Analysen von Elektromotoren, komplexer Aktuatoren und elektronischen Steuergeräten belegt. Die bei den Prognosen gewonnenen Ergebnisse werden beispielhaft kurz dargestellt und diskutiert. Der Nutzen und die Bedeutung der Prognoseergebnisse wird durch praktische Anwendungen gezeigt. So wird das entwickelte Zuverlässigkeitsprognosemodell als Werkzeug in der Produktentwicklung zur Bewertung von Designänderungen und als Unterstützung bei betrieblichen Entscheidungsprozessen eingesetzt. Weiterführend werden die Kosten für die Ausweitung der Garantiezeit und der für ein Produkt benötigte Ersatzbedarf geschätzt.

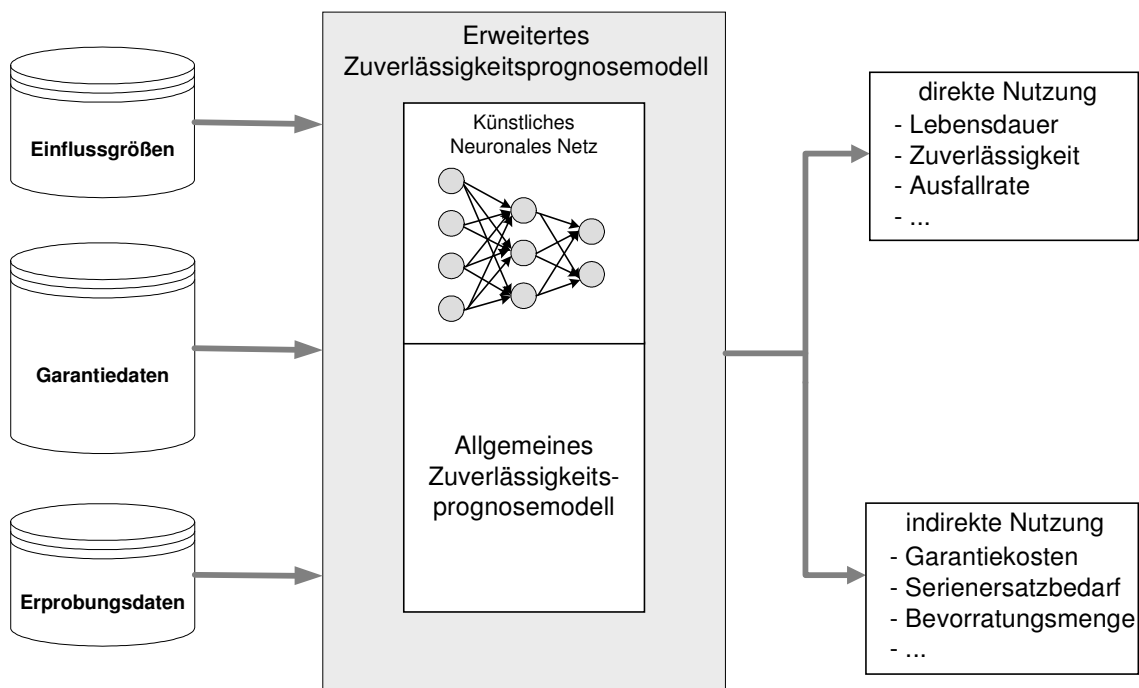
Für ein Unternehmen besteht in der Praxis häufig die Anforderung, möglichst frühzeitig Aussagen über die zu erwartende Produktzuverlässigkeit zu machen. Dabei ist die Zeitspanne zwischen dem letzten Garantiefall und dem Zeitpunkt der Prognose von besonderem Interesse. Ist diese Zeitspanne relativ kurz und wurden die Komponenten bis vor kurzem noch gefertigt oder werden diese noch gefertigt, spricht man von zeitnahen Garantiedaten. Diese Daten enthalten auf Grund eines Zulassungs- und Meldeverzugs jedoch meist nicht alle Informationen über das tatsächliche Ausfallaufkommen. In Kapitel 5 wird ein neues Zuverlässigkeitsprognosemodell entwickelt, mit dem auch solche unvollständigen, zeitnahen Daten für die Prognose genutzt werden können. Hierzu werden die Einflussgrößen entsprechend modelliert und in das entwickelte allgemeine Zuverlässigkeitsprognosemodell integriert. Das neue Zuverlässigkeitsprognosemodell für zeitnahe Daten wird anhand umfangreicher Simulationen überprüft und für reale Felddaten angewendet.

Das Ausfallverhalten von Komponenten und Baugruppen im Kraftfahrzeug ist oft von weiteren externen Einflussgrößen, wie den Umgebungsbedingungen, dem Einbauort sowie der Nutzungsart abhängig. Eine Schwierigkeit besteht darin, die Wirkungsweise solcher Einflüsse funktional zu beschreiben. In Kapitel 6 wird eines neues, erweitertes Zuverlässigkeitsprognosemodell entwickelt, das solche sich ändernde Parameter bei der Prognose berücksichtigt. Eine Alternative zu klassisch statistischen Methoden zur Mo-



dellierung externer Einflüsse, sind die Künstlichen Neuronen Netze (KNN). Diese lernfähigen Algorithmen sind in der Lage, unbekannte funktionale Zusammenhänge auch bei geringen Vorkenntnissen zu erfassen, abzubilden und zu verarbeiten. In dem Kapitel wird zunächst ein allgemeines neuronales Modell zur Funktionsapproximation entwickelt und erläutert. Ziel ist es, ein erweitertes neuronales Zuverlässigkeitsprognosemodell für die Analyse eines Elektromotors bei wechselnden klimatischen Bedingungen einzusetzen. Hierzu werden mögliche Einflussgrößen identifiziert und für die Analyse entsprechend transformiert. Durch die Variation verschiedener Netzparameter nach einem entwickelten Versuchsplan wird eine für die Aufgabe geeignete Netzarchitektur bestimmt. Das entwickelte Netz wird mit Hilfe realer Daten trainiert und erlernt so die funktionalen Zusammenhänge zwischen den Einflussgrößen und dem Ausfallverhalten. Mit Hilfe des entwickelten neuronalen Modells ist es dann möglich, die Ausfallwahrscheinlichkeit in Abhängigkeit von verschiedenen Einflussfaktoren zu prognostizieren.

Bild 1.4 zeigt den Ansatz des neuen erweiterten Zuverlässigkeitsprognosemodells mit den notwendigen Eingangsgrößen und verschiedenen Nutzungsmöglichkeiten für die prognostizierten Zuverlässigkeitskenngrößen.



**Bild 1.4:** Erweitertes Zuverlässigkeitsprognosemodell

Die Arbeit endet mit einer Zusammenfassung der wichtigsten Ergebnisse und gibt einen Ausblick auf zukünftige Fragestellungen.

Im Anhang der Arbeit befindet sich ein Verzeichnis der verwendeten Symbole und Abkürzungen sowie eine detaillierte Darstellung aller Analyse- und Prognoseergebnisse. Eine Zusammenfassung der umfangreichen Simulationsergebnisse für das zeitnahe Prognosemodell ist ebenfalls dem Anhang beigefügt. Des Weiteren werden auch die Trainingsabläufe aller entwickelten Neuronalen Netze mit den zugehörigen Gütemaßen aufgeführt.

Alle entwickelten statistischen Modelle wurden in der mathematischen Entwicklungsssoftware Mathematica™ 4.0 mit Hilfe eigener Programme und Algorithmen umgesetzt. Für die Simulation der zeitnahen Analysen wurden ebenfalls mehrere Programme entwickelt. Die Modellierung der Neuronalen Netze erfolgte mit Hilfe der Software SNNS.

## 2 Grundlagen

Nachfolgend werden einige wichtige Grundlagen aus der Statistik, der Zuverlässigkeitstheorie und der Theorie Neuronaler Netze kurz dargestellt. Die Grundlagen dienen dem besseren Verständnis der Arbeit.

### 2.1 Statistik

#### 2.1.1 Grundgesamtheit und Stichprobe

Als Grundgesamtheit bezeichnet man die Gesamtheit aller Merkmalsträger, die in einer statistischen Untersuchung auftreten können. Wird aus einer Grundgesamtheit ein Element zufällig ausgewählt und der Wert des zugehörigen Merkmals gemessen, so kann der Wert  $x$  als Realisation einer Zufallsvariablen  $X$  aufgefasst werden. Für ein Intervall  $I$  ist also  $P(X \in I)$  die Wahrscheinlichkeit dafür, dass ein Element aus der Grundgesamtheit ausgewählt wird, dessen Merkmalswert in  $I$  liegt. Die Verteilungsparameter und die Verteilungsfunktion der Grundgesamtheit charakterisieren damit die Zufallsvariable  $X$ .

Ist eine Totalerhebung, bei der alle Merkmalsausprägungen gemessen werden, nicht möglich, werden einige Objekte der Grundgesamtheit repräsentativ ausgewählt. Man nennt eine solche Menge von  $n$  Objekten eine Stichprobe vom Umfang  $n$ . Jede Funktion der Stichprobenvariable nennt man eine Stichprobenfunktion oder Statistik. Die Statistiken können zu folgenden Zwecken genutzt werden:

- zur Schätzung von Parametern der Grundgesamtheit,
- zur Schätzung eines Intervalls, das mit einer vorgegebenen Sicherheitswahrscheinlichkeit den wahren Parameter enthält,
- zur Überprüfung von Hypothesen, ob ein Parameter in einer bestimmten Region liegt und zur Prognose.

Beispiele für Stichprobenfunktionen sind das arithmetische Mittel, das geometrische Mittel oder auch das Maximum.

Hält man bei einer Stichprobenentnahme den Stichprobenumfang  $n$  fest und führt die Stichprobenentnahme mehrmals aus, wird die Stichprobenfunktion einer Verteilung folgen. Eine solche Verteilung nennt man Stichprobenverteilung. Stichprobenverteilungen von besonderer Bedeutung sind die Prüfverteilungen (z.B.  $\chi^2$ -,  $F$ -,  $t$  Verteilung).

Mit Hilfe dieser Verteilungen lassen sich u.a. die kritischen Schranken für Hypothesentests bestimmen.

### 2.1.2 Parameterschätzung

Ziel der Parameterschätzung ist es, mit Hilfe einer Stichprobe, Aussagen über die Verteilung der Grundgesamtheit zu ermöglichen. Man unterscheidet dabei die Punkt- und die Intervallschätzung. Bei der Punktschätzung erhält man einen Schätzwert  $\hat{\theta}$  für den zu bestimmenden Parameter  $\theta$  der gesuchten Verteilung. Bei der Intervallschätzung konstruiert man dagegen ein Intervall, das den unbekannten Parameter im Mittel mit vorgegebener Vertrauenswahrscheinlichkeit enthalten wird.

Die zu bestimmende Schätzfunktion  $\hat{\theta}(x_1, \dots, x_n)$  einer Zufallsstichprobe  $x_1, \dots, x_n$  muss hinsichtlich ihrer Güte einigen Anforderungen genügen. Kriterien hierfür sind:

- Erwartungstreue: Eine Schätzung heißt erwartungstreu, wenn gilt:  

$$E(\hat{\theta}) = \theta.$$
- Effizienz: Ein Maß für die Effizienz einer Schätzfunktion ist deren Varianz. Dabei gilt je kleiner die Varianz desto effizienter der Schätzer.
- Konsistenz: Damit ein Schätzer konsistent ist, sollte er für große Stichprobenumfänge einen möglichst kleinen zufälligen Fehler aufweisen, d.h.  

$$\lim_{n \rightarrow \infty} P(|\hat{\theta} - \theta| > \varepsilon) = 0, \quad \varepsilon > 0.$$
- Suffizienz: Unter der Suffizienz versteht man die Berücksichtigung aller in einer Stichprobe enthaltenen Informationen zur Bestimmung von Schätzfunktionen.

Zur Herleitung von Schätzfunktionen wurden verschieden Verfahren entwickelt. Im Folgenden sollen nur einige wichtige Methoden kurz vorgestellt werden.

#### Momentenmethode

Man erhält eine Schätzung nach der Momentenmethode, wenn man den zu schätzenden Parameter durch die theoretischen Momente der Verteilungen ausdrückt und diese in der so erhaltenen Formel durch die empirischen Momente ersetzt. Dabei ist das k-te empirische Moment der Stichprobe  $x_1, \dots, x_n$  gegeben durch

$$m_k = \frac{1}{n} \sum_{j=1}^n x_j^k \quad (2.1)$$

und das  $k$ -te theoretische Moment der gesuchten Verteilung durch

$$M_k = \int_{-\infty}^{+\infty} x^k \cdot f_x(x) dx . \quad (2.2)$$

Die Momentenmethode ist jedoch nur anwendbar, wenn für die theoretische Verteilungsfunktion mindestens genauso viele Momente existieren, wie unbekannte Parameter zu schätzen sind. Für die Betrachtung zensierter Stichproben ist die Momentenmethode nicht geeignet.

### Maximum-Likelihood-Methode

Die Maximum-Likelihood-Methode beruht auf folgendem Schätzprinzip: Als Schätzwert für einen unbekannt Parameter einer Wahrscheinlichkeitsverteilung verwendet man einen solchen Wert des Parameters, bei dessen vorliegen, der konkreten Stichprobe eine möglichst große Wahrscheinlichkeit zukommt [Mai76].

Ausgangspunkt der Methode ist eine Zufallsgröße  $X$ , für die eine vom unbekannt Parameter  $\theta$  abhängige Dichtefunktion  $f(x|\theta)$  existiert.

Liegt eine Stichprobe vom Umfang  $n$  vor, lässt sich die zugehörige Dichtefunktion der Stichprobe folgendermaßen angeben:

$$\prod_{i=1}^n f(x_i|\theta) = f(x_1|\theta) \dots \cdot f(x_n|\theta) . \quad (2.3)$$

Bei der so genannten Likelihoodfunktion  $L(\theta|x)$  rückt der unbekannt Parameter in den Vordergrund. Dabei werden die Werte der Stichprobe als gegeben und der zu schätzende Parameter  $\theta$  als Variable aufgefasst.

Die Maximum-Likelihood-Methode besteht nun darin, dass man als Schätzung des Parameters  $\theta$  den Wert  $\hat{\theta}$  wählt, bei dem die Likelihoodfunktion ihr Maximum erreicht. Aus rechentechnischen Gründen verwendet man häufig auch die logarithmierte Likelihoodfunktion  $\ln L(\theta|x)$  zur Bestimmung des Maximums. Jede Lösung dieser Gleichungen heißt dann Maximum-Likelihood-Schätzung  $\hat{\theta}$  des Parameters  $\theta$ .

Für die Likelihoodfunktion ergibt sich bei einer Typ-II-Zensierung, d.h. Abbruch der Untersuchung nach  $r$  Realisierungen bei  $n$  möglichen, folgende Form:

$$L(\theta|x) = \frac{n!}{(n-r)!} \prod_{i=1}^r f(x_i) \cdot [1 - F(x_r)]^{n-r} , \quad (2.4)$$

mit  $x_r$  : Wert von  $x$  bei  $r$ -ten-Realisierung.

Die Maximum-Likelihood-Methode ist von großer praktischer Bedeutung und wird vielseitig eingesetzt.

### Methode der kleinsten Quadrate

Die Methode der kleinsten Quadrate zur Schätzung der Parameter einer Verteilung ist eine Weiterführung der linearen Regressionsrechnung. Die Idee dieses Ansatzes besteht darin, die Abweichung zwischen empirischer und theoretischer Verteilung zu minimieren. Als Maß für diese Abweichung dient die Summe der Abweichungsquadrate (*SSE*). Die zu schätzenden Parameter sollen daher so ermittelt werden, dass diese Summe minimal wird.

$$SSE = \sum_{i=1}^n (F(x_i) - \tilde{F}(x_i))^2 \rightarrow \text{Min}. \quad (2.5)$$

Die zu schätzenden Parameter lassen sich durch Null setzen der partiellen Ableitungen von *SSE* bestimmen. Bei vielen Verteilungsfunktionen können die Parameter jedoch nur numerisch ermittelt werden. Um geeignete Startwerte für die numerische Berechnung zu finden, kann man diese mittels linearer Regression vorbestimmen. Dazu wird die theoretische Verteilungsfunktion linearisiert und daraus eine erste Schätzung der Parameter abgeleitet. Diese bilden dann die Startwerte für die Methode der kleinsten Quadrate.

#### 2.1.3 Konfidenzintervalle

Das Konfidenzintervall  $[\hat{\theta}_u, \hat{\theta}_o]$ , auch Vertrauensbereich genannt, ist ein aus Stichprobenwerten berechnetes zufälliges Intervall, das den wahren aber unbekanntem Parameter  $\theta$  mit einer vorgegebenen Vertrauenswahrscheinlichkeit  $1 - \alpha$  überdeckt.  $\alpha$  wird Irrtumswahrscheinlichkeit genannt.  $\hat{\theta}_u$  kennzeichnet dabei die untere und  $\hat{\theta}_o$  die obere Vertrauensgrenze. Man unterscheidet drei Arten von Konfidenzintervallen:

1. zentral oder beidseitig begrenzt

$$P(\hat{\theta}_u \leq \theta \leq \hat{\theta}_o) = 1 - \alpha,$$

2. einseitig, oben begrenzt

$$P(\theta \leq \hat{\theta}_o) = 1 - \alpha,$$

3. einseitig, unten begrenzt

$$P(\theta \geq \hat{\theta}_u) = 1 - \alpha.$$

Typische vorgegebene Vertrauenswahrscheinlichkeiten für statistische Verfahren sind 99%, 95% und 90%. Für die jeweiligen Fragestellungen existieren eine Vielzahl verschiedener Verfahren zur Bestimmung der zugehörigen Vertrauensintervalle. Die meisten Konfidenzintervalle lassen sich mit Hilfe von Prüfverteilungen ermitteln. In manchen Fällen lässt sich der Vertrauensbereich jedoch nur durch Simulationen approximieren. Eine Möglichkeit zur Simulation von Konfidenzintervallen ist die Bootstrap-Methode. Eine vertiefende Darstellung zu Konfidenzintervallen findet man u.a. in [Hah91].

## 2.2 Zuverlässigkeitstheorie

### 2.2.1 Theoretische Zuverlässigkeitskenngrößen

Die Lebensdauer  $T$  einer Komponente oder eines technischen Systems ist eine nicht negative stetige Zufallsvariable. Sie kann als Zeit, gefahrene Strecke, Betriebszyklen oder sonstige Größe angegeben werden. Mit Hilfe dieser Zufallsvariablen lassen sich die im Folgenden dargestellten Kenngrößen bestimmen.

#### Ausfallwahrscheinlichkeit

Die Ausfallwahrscheinlichkeit  $F(t)$  wird wahrscheinlichkeitstheoretisch als Verteilungsfunktion der Lebensdauer bezeichnet und stellt die Wahrscheinlichkeit dar, dass die Lebensdauer  $T$  eine betrachtete Betriebsdauer ab Anwendungsbeginn nicht erreicht. Daraus ergibt sich folgende Gleichung:

$$F(t) = P(T \leq t), \quad (2.6)$$

mit  $F(t) = 0 \quad \forall t \leq 0$ .

Die Ausfallwahrscheinlichkeit ist eine monoton wachsende Funktion. Das bedeutet, dass nach einem hinreichend langen Zeitraum alle nicht reparierbaren Betrachtungseinheiten ausgefallen sind. Es gilt daher:

$$\lim_{t \rightarrow \infty} F(t) = 1.$$

#### Überlebenswahrscheinlichkeit

Das Komplement zur Ausfallwahrscheinlichkeit ist die Überlebenswahrscheinlichkeit, die auch Zuverlässigkeitsfunktion  $R(t)$  genannt wird:

$$R(t) = P(T > t) = 1 - F(t), \quad (2.7)$$

mit dem Grenzwert  $\lim_{t \rightarrow \infty} R(t) = 0$ .

Die Überlebenswahrscheinlichkeit ist eine monoton fallende Funktion.

### Ausfalldichte

Die Ausfalldichte  $f(t)$  gibt den relativen Anteil von ausgefallenen Betrachtungseinheiten, je Zeiteinheit, Kilometerintervall oder Anzahl der Schaltvorgänge, bezogen auf den Anfangsbestand der Betrachtungseinheiten an. Bei stetigen Dichtefunktionen ergibt sich die Ausfalldichte aus der ersten Ableitung der Ausfallwahrscheinlichkeit:

$$f(t) = \frac{dF(t)}{dt} \quad \forall t > 0. \quad (2.8)$$

### Ausfallrate

Eine weitere wichtige Lebensdauerkenngroße ist die Ausfallrate  $h(t)$  mit dem formelmäßigen Zusammenhang:

$$h(t) = \lim_{\Delta t \rightarrow \infty} \frac{P(t < T \leq t + \Delta t | T > t)}{\Delta t} = \frac{f(t)}{R(t)} = -\frac{d \ln R(t)}{dt}. \quad (2.9)$$

Das Produkt  $h(t) \cdot \Delta t$  bestimmt für hinreichend kleine Zeitintervalle  $\Delta t$  die Wahrscheinlichkeit, dass eine Betrachtungseinheit im Intervall  $[t, t + \Delta t]$  unter der Bedingung ausfallen wird, dass sie bis zum Zeitpunkt  $t$  überlebt hat. Sie beschreibt demzufolge die momentane Ausfallneigung einer Betrachtungseinheit zum Zeitpunkt  $t$ , ist also ein Maß für die Anfälligkeit eines Elementes in Abhängigkeit von seinem Alter [Köc83]. Aus diesem Grund kann sie auch als bedingte Ausfallwahrscheinlichkeit je Zeiteinheit aufgefasst werden, die immer von dem vorhandenen Bestand der zum Zeitpunkt  $t$  funktionsfähigen Betrachtungseinheiten abhängt.

### Mittlere Lebensdauer

Unter der mittleren Lebensdauer versteht man den Mittelwert der ausfallfreien Betriebszeit einer Betrachtungseinheit. Sie ergibt sich aus dem Erwartungswert  $E(T)$ :

$$E(T) = \int_0^{\infty} t \cdot f(t) dt = \int_0^{\infty} R(t) dt. \quad (2.10)$$

Die Mittlere Lebensdauer wird auch häufig als MTTF (mean time to failure) bezeichnet.

Die vorgestellte Zuverlässigkeitskenngroßen lassen sich alle ineinander überführen bzw. umrechnen. Die folgende Tabelle 2.1 zeigt die jeweiligen Berechnungen der Kenngroßen und deren Zusammenhang.



Tabelle 2.1: Zusammenhang zwischen den stetigen Zuverlässigkeitskenngrößen [Mey94]

	Ausfallwahrscheinlichkeit $F(t)$	Überlebenswahrscheinlichkeit $R(t)$	Ausfalldichte $f(t)$	Ausfallrate $h(t)$
$F(t)$		$1 - R(t)$	$\int_0^t f(\tau) d\tau$	$1 - \exp\left(-\int_0^t h(\tau) d\tau\right)$
$R(t)$	$1 - F(t)$		$\int_t^\infty f(\tau) d\tau$	$\exp\left(-\int_0^t h(\tau) d\tau\right)$
$f(t)$	$\frac{d F(t)}{dt}$	$-\frac{d R(t)}{dt}$		$h(t) \cdot \exp\left(-\int_0^t h(\tau) d\tau\right)$
$h(t)$	$\frac{1}{1 - F(t)} \cdot \frac{d F(t)}{dt}$	$-\frac{1}{R(t)} \cdot \frac{d R(t)}{dt}$	$\frac{f(t)}{\int_t^\infty f(\tau) d\tau}$	

### 2.2.2 Empirische Zuverlässigkeitskenngrößen

Die empirischen Zuverlässigkeitskenngrößen werden aus experimentell gewonnenen Daten bestimmt. Dabei ist  $n_0$  die Anzahl aller im Test berücksichtigten gleichen Betriebseinheiten. Unter  $n_a(t)$  versteht man die Anzahl der bis zu einem festgelegten Zeitpunkt  $t$  ausgefallenen Betriebseinheiten und unter  $n_b(t)$  die Anzahl der bis zum Zeitpunkt  $t$  noch intakten Einheiten. Die empirischen Zuverlässigkeitskenngrößen werden zusätzlich mit einer Tilde gekennzeichnet und sind inhaltlich identisch mit den theoretischen Kenngrößen [Mey94].

#### Empirische Ausfallwahrscheinlichkeit

Die empirische Ausfallwahrscheinlichkeit ist definiert als das Verhältnis der bis zu einem Zeitpunkt ausgefallenen Betriebseinheiten zur Grundgesamtheit:

$$\tilde{F}(t) = \frac{n_a(t)}{n_0}. \quad (2.11)$$

### Empirische Überlebenswahrscheinlichkeit

Sie ist entsprechend festgelegt als das Verhältnis der zu einem Zeitpunkt noch funktionsfähigen Betriebseinheiten zur Grundgesamtheit:

$$\tilde{R}(t) = \frac{n_b(t)}{n_0}. \quad (2.12)$$

### Empirische Ausfalldichte

Finden im  $i$ -ten Zeitintervall der Länge  $\Delta t_i$ , in dem der Zeitpunkt  $t$  liegt, insgesamt  $\Delta n_{a,i}$  Ausfälle statt, dann lautet die zugehörige Ausfalldichte:

$$\tilde{f}(t) = \frac{1}{n_0} \cdot \frac{\Delta n_{a,i}}{\Delta t_i}. \quad (2.13)$$

### Empirische Ausfallrate

Die empirische Ausfallrate ergibt sich aus der Anzahl der in einem bestimmten Zeitintervall  $\Delta t_i$  ausgefallenen Betriebseinheiten  $\Delta n_{a,i}$ , bezogen auf die zum Ende des Zeitintervalls noch funktionsfähigen Betriebseinheiten:

$$\tilde{h}(t) = \frac{1}{n_b(t)} \cdot \frac{\Delta n_{a,i}}{\Delta t_i} = \frac{\tilde{f}(t)}{\tilde{R}(t)}. \quad (2.14)$$

Wie bei den stetigen Zuverlässigkeitskenngrößen, lässt sich auch der Zusammenhang der empirische Kenngrößen in einer Tabelle darstellen (Tabelle 2.2).

Tabelle 2.2: Zusammenhang zwischen den empirischen Zuverlässigkeitskenngrößen

	Ausfallwahrscheinlichkeit $\tilde{F}(t_i) = \frac{n_a(t_i)}{n_0}$	Überlebenswahrscheinlichkeit $\tilde{R}(t_i) = \frac{n_b(t_i)}{n_0}$	Ausfalldichte $\tilde{f}(t_i) = \frac{\Delta n_{a,i}}{n_0(t_i - t_{i-1})}$	Ausfallrate $\tilde{h}(t_i) = \frac{\Delta n_{a,i}}{n_b(t_i)(t_i - t_{i-1})}$
$\tilde{F}(t_i)$		$1 - \tilde{R}(t_i)$	$\sum_{j=1}^i (\tilde{f}(t_j) \cdot (t_j - t_{j-1}))$	$1 - ((\sum_{j=1}^i (\tilde{h}(t_j) \cdot n_b(t_j) \cdot (t_j - t_{j-1}))) / n_0)$
$\tilde{R}(t_i)$	$1 - \tilde{F}(t_i)$		$1 - \sum_{j=1}^i (\tilde{f}(t_j) \cdot (t_j - t_{j-1}))$	$(\sum_{j=1}^i (\tilde{h}(t_j) \cdot n_b(t_j) \cdot (t_j - t_{j-1}))) / n_0$
$\tilde{f}(t_i)$	$\frac{\tilde{F}(t_i) - \tilde{F}(t_{i-1})}{t_i - t_{i-1}}$	$-\frac{\tilde{R}(t_{i-1}) - \tilde{R}(t_i)}{t_{i-1} - t_i}$		$\frac{\tilde{h}(t_i) \cdot n_b(t_i)}{n_0}$
$\tilde{h}(t_i)$	$\frac{\tilde{F}(t_i) - \tilde{F}(t_{i-1})}{(1 - \tilde{F}(t_i))(t_i - t_{i-1})}$	$-\frac{\tilde{R}(t_{i-1}) - \tilde{R}(t_i)}{\tilde{R}(t_i)(t_{i-1} - t_i)}$	$\frac{\tilde{f}(t_i)}{1 - \sum_{j=1}^i (\tilde{f}(t_j) \cdot (t_j - t_{j-1}))}$	

### 2.2.3 Verteilungsfunktionen

Im Folgenden sollen einige wichtige für diese Arbeit relevante Verteilungsfunktionen kurz eingeführt werden.

#### Exponentialverteilung

Eine Zufallsvariable  $T$  heißt exponentialverteilt mit dem Parameter  $\lambda > 0$ , wenn sie folgende Dichte besitzt:

$$f(t) = \lambda \cdot e^{-\lambda t} \quad \forall t \geq 0. \quad (2.15)$$

### Weibull-Verteilung

Eine Zufallsvariable  $T$  heißt Weibull-verteilt mit den Parametern  $\alpha > 0$  und  $\beta > 0$ , wenn sie folgende Dichte besitzt:

$$f(t) = \alpha \cdot \beta \cdot t^{\beta-1} \cdot e^{-\alpha t^\beta} \quad \forall t \geq 0. \quad (2.16)$$

### Normalverteilung

Eine Zufallsvariable  $T$  heißt normalverteilt mit den Parametern  $\mu \in \mathbb{R}$  und  $\sigma > 0$ , wenn sie folgende Dichte besitzt:

$$f(t) = \frac{1}{\sqrt{2 \cdot \pi} \cdot \sigma} \cdot e^{-\frac{(t-\mu)^2}{2\sigma^2}} \quad -\infty \leq t \leq +\infty. \quad (2.17)$$

### Logarithmische Normalverteilung

Eine Zufallsvariable  $T$  heißt logarithmisch-normalverteilt mit den Parametern  $\mu \in \mathbb{R}$  und  $\sigma > 0$ , wenn sie folgende Dichte besitzt:

$$f(t) = \frac{1}{\sqrt{2 \cdot \pi} \cdot \sigma \cdot t} \cdot e^{-\frac{(\ln t - \mu)^2}{2\sigma^2}} \quad \forall t \geq 0. \quad (2.18)$$

## 2.3 Neuronale Netze

Künstliche Neuronale Netze (KNN) erlangen in den letzten Jahren in verschiedensten Forschungsbereichen und praktischen Anwendungsgebieten in der Ökonomie, der Physik oder in den Ingenieurwissenschaften immer mehr an Bedeutung. Die Grundidee der KNN ist, die Funktionsweise des menschlichen Gehirns nachzubilden. Das menschliche Gehirn hat die für einen Computer wünschenswerten Fähigkeiten, schnell abstrakte Strukturen zu generalisieren und Muster auch bei unvollständigen oder verrauschten Daten zu erkennen. Es kann probabilistische und unscharfe Formulierungen verstehen, interpretieren und entsprechend handeln. Es ist außerdem in der Lage, schnell gespeicherte Informationen abzurufen und lokale Verletzungen oder Beschädigungen ohne Verlust der gesamten Funktionalität auszugleichen (Fehlertoleranz).

In der Statistik sind die Neuronalen Netze vor allem für Prognose- und Klassifizierungsprobleme von Interesse. Sie wurden schon in verschiedensten Bereichen, in denen

sonst traditionell statistische Methoden eingesetzt werden, angewandt. Beispiele hierfür sind die Identifizierung von Unterwasser-Sonar-Signale [Gor88] und die Vorhersage von Herzfehlern bei Patienten [Bax90, Fuj92]. Bei Zeitreihenanalysen wurden sie u.a. auch für die Prognose von Aktienkursen genutzt [Hut94].

### 2.3.1 Biologisches Vorbild


Die wesentliche Aufgabe des menschlichen Gehirns ist die Reizaufnahme, die Reizverarbeitung und die Beantwortung von Reizen. Die Rezeptoren nehmen Reize beispielsweise durch Licht, Druck, Temperatur und Töne auf und kodieren diese, so dass sie über Reizbahnen an das Gehirn weitergeleitet werden können. Diese elektrochemischen Informationen werden dann im Gehirn nach gespeicherten Mustern verarbeitet und gegebenenfalls ein Reaktionsreiz an die Effektoren ausgesandt. Beim menschlichen Gehirn unterscheidet man zwischen dem animalischen, welches für das bewusste Verarbeiten von Informationen verantwortlich ist und dem vegetativen Nervensystem, wobei letzteres für die unbewussten bzw. reflexartigen Handlungen zuständig ist. Die Informationsverarbeitung innerhalb des Gehirns findet vorwiegend in der Hirnrinde (Neokortex) statt.

Das menschliche Nervensystem besteht aus mehr als  $10^{10}$  Nervenzellen (Neuronen) [Bra95]. Das Neuron ist die strukturelle und funktionelle Einheit des Nervensystems. Ein typisches Neuron besitzt einen Zellkörper (Soma), der zwei Arten von Fortsätzen, das Axon und die Dendriten, hat. Über die große Oberfläche der Dendriten nimmt die Nervenzelle Signale von anderen Neuronen auf. Das Axon, das am Axonhügel des Somas entspringt überträgt das Nervensignal auf andere Nerven-, Muskel- und Drüsenzellen. Es endet mit den so genannten Endknöpfen an der Synapse und nimmt dort Verbindung zum Soma, zu den Dendriten oder zum Axon des eines anderen Neurons auf. An einem einzelnen Neuron finden sich Tausende solcher Kontaktstellen, die bis zu 40% der Neuronenoberfläche bedecken können [Sil91].

Die Informationsübertragung zwischen den Nervenzellen erfolgt mit Hilfe elektrischer Signale. Die Funktionsweise der Neuronen beruht auf dem Membranpotential, das die Spannung zwischen Zellmembran und Umgebung wiedergibt. Im Ruhezustand besitzt die Zelle ein Membranpotential von ca.  $-75\text{mV}$ . Wird die Zelle von außen erregt und überschreitet das Membranpotential einen Schwellenwert von etwa  $-50\text{mV}$ , kommt es zu einem plötzlichen, für einige Millisekunden dauernden Potentialanstieg auf ca.  $+30\text{mV}$ . Dieser kurze Spannungsanstieg wird auch Erregungszustand oder Aktionspotential genannt und charakterisiert das sogenannte „Feuern“ oder „Schalten“ der Zelle.

Das Aktionspotential pflanzt sich längs des Axons fort und veranlasst die Freisetzung von Neurotransmittern an der präsynaptischen Membran, die über den synaptischen Spalt zu anderen Nervenzellen diffundieren und dort erneut elektrische Veränderungen bewirken. Je nach Art der Überträgerstoffe wird dabei die synaptische Übertragung gehemmt oder verstärkt. Da die Synapsen ihre hemmende oder verstärkende Wirkung mit der Zeit verändern können, spielen sie bei Lernvorgängen eine wichtige Rolle.

Bild 2.1 zeigt die schematische Darstellung eines menschlichen Neurons mit seinen Bestandteilen.



**Bild 2.1: Vereinfachte Struktur eines Neurons**

### 2.3.2 Geschichte Neuronaler Netze

Die Anfänge der Entwicklung Neuronaler Netze lässt auf die Arbeit von McCulloch und Pitts im Jahr 1943 zurückführen. Sie beschrieben neurologische Netzwerke basierend auf dem „McCulloch-Pitts“-Neuron und zeigten, dass einfache Klassen Neuronaler Netze prinzipiell jede arithmetische oder logische Funktion berechnen können [McC43]. Diese Neuronalen Netze waren jedoch noch nicht lernfähig. Der erste, der ein solches Konzept anregte, war der Psychologe Donald O. Hebb. Er formulierte 1949 die Hebb'sche Lernregel als einfaches universelles Lernkonzept individueller Neuronen,


das bis heute die Basis fast aller neuronaler Lernverfahren darstellt [Heb49]. In den frühen 60er Jahren entwickelte Rosenblatt das Modell des Perzeptrons [Ros58]. Das einfache Perzeptron besteht aus mehreren McCulloch-Pitts Neuronen, die in einer Eingabe- und einer Ausgabeschicht angeordnet sind. Rosenblatt konnte zeigen, dass wenn eine Lösung für ein Klassifizierungsproblem existiert, das Netz gegen diese Lösung in einer endlichen Anzahl von Schritten konvergiert (Perzeptron-Konvergenz-Theorem). Minsky und Papert führten in [Min69] eine genaue mathematische Analyse des Perzeptrons durch und zeigten, dass das Modell jedoch viele wichtige Probleme nicht repräsentieren und nur für linear separierbare Problem verwendet werden kann. Teuvo Kohonen stellte im Jahr 1972 ein Modell des linearen Assoziators vor [Koh72], das im gleiche Jahr unabhängig auch aus neurophysiologischer Sicht von Anderson beschrieben wurde [And72]. Eine weitere wichtige Entwicklung Kohonens sind die selbstorganisierenden Karten [Koh82, Koh84]. John Hopfield, ein bekannter Physiker, entwickelte die binären Hopfield-Netze als neuronales Äquivalent zu physikalischen Modellen. Im Jahr 1985 konnte Hopfield zeigen, dass mit den Hopfield-Netzen schwierige Optimierungsaufgaben, wie das Travelling-Salesman-Problem, gelöst werden können [Hop85]. Einen besonders großen Einfluss auf die weitere Entwicklung neuronaler Netze hatte die Publikation des Backpropagation-Lernverfahrens durch Rumelhart, Hinton und Williams [Rum86]. Dieses für mehrstufige vorwärtsgerichtete Netze entwickelte Lernverfahren war wesentlich schneller und robuster im Vergleich zu bisherigen Lernverfahren. Eine detaillierte Beschreibung weiterer Entwicklungen Neuronaler Netze findet man u.a. in [Zel00, Roj93, Kin94].

### 2.3.3 Theorie Künstlicher Neuronaler Netze

Die im Weiteren hier vorgestellten Neuronalen Netze haben mit dem biologischen Vorbild des menschlichen Gehirns nur noch recht wenig gemeinsam. Das genaue Nachbilden der menschlichen Gehirnfunktion ist Bestandteil einer eigenen Forschungsrichtung in der Biomedizin.

Ein Künstliches Neuronales Netz ist eine stark vernetzte Struktur einfacher Recheneinheiten, wobei die Recheneinheit vereinfacht den biologischen Neuronen entsprechen. Ein einfaches Neuron kann lediglich zwei Zustände annehmen, entweder es „feuert“ oder es ist passiv. Man kann daher dem Neuron als Ausgangswert  $a_i$  entsprechend die Werte 1 und 0 zuordnen. Die Eingangswerte  $e_i$  des Neurons sind die Ausgabewerte  $a_j$  vorgeschalteter Neuronen und können daher ebenfalls nur den Wert 0 oder 1 besitzen. Entsprechend der biologischen Funktionsweise der Synapsen werden die Eingangssignale verstärkt oder gehemmt. Bei dem Modell der künstlichen Neuronalen Netze ge-

schiebt dies durch die Multiplikation mit einem Gewichtungsfaktor  $w_{ij}$ . Ein Neuron feuert bzw. ist aktiv, wenn die Summe der gewichteten Eingangssignale einen Schwellenwert  $\Theta_i$  überschreitet. Der Aufbau eines solchen einfachen Neurons ist in Bild 2.2 dargestellt.



**Bild 2.2: Einfaches Modell eines Neuron**

Mathematisch lässt sich das Modell eines Neurons in der folgenden Form darstellen:

$$y_i = f_a(x) = f_a\left(\sum_j w_{ij} \cdot e_j - \Theta_i\right). \quad (2.19)$$

Die Aktivierungsfunktion  $f_a(x)$  ist dabei wie folgt definiert:

$$f_a(x) = \begin{cases} 1 & \text{für } x > 0, \\ 0 & \text{für } x \leq 0. \end{cases} \quad (2.20)$$

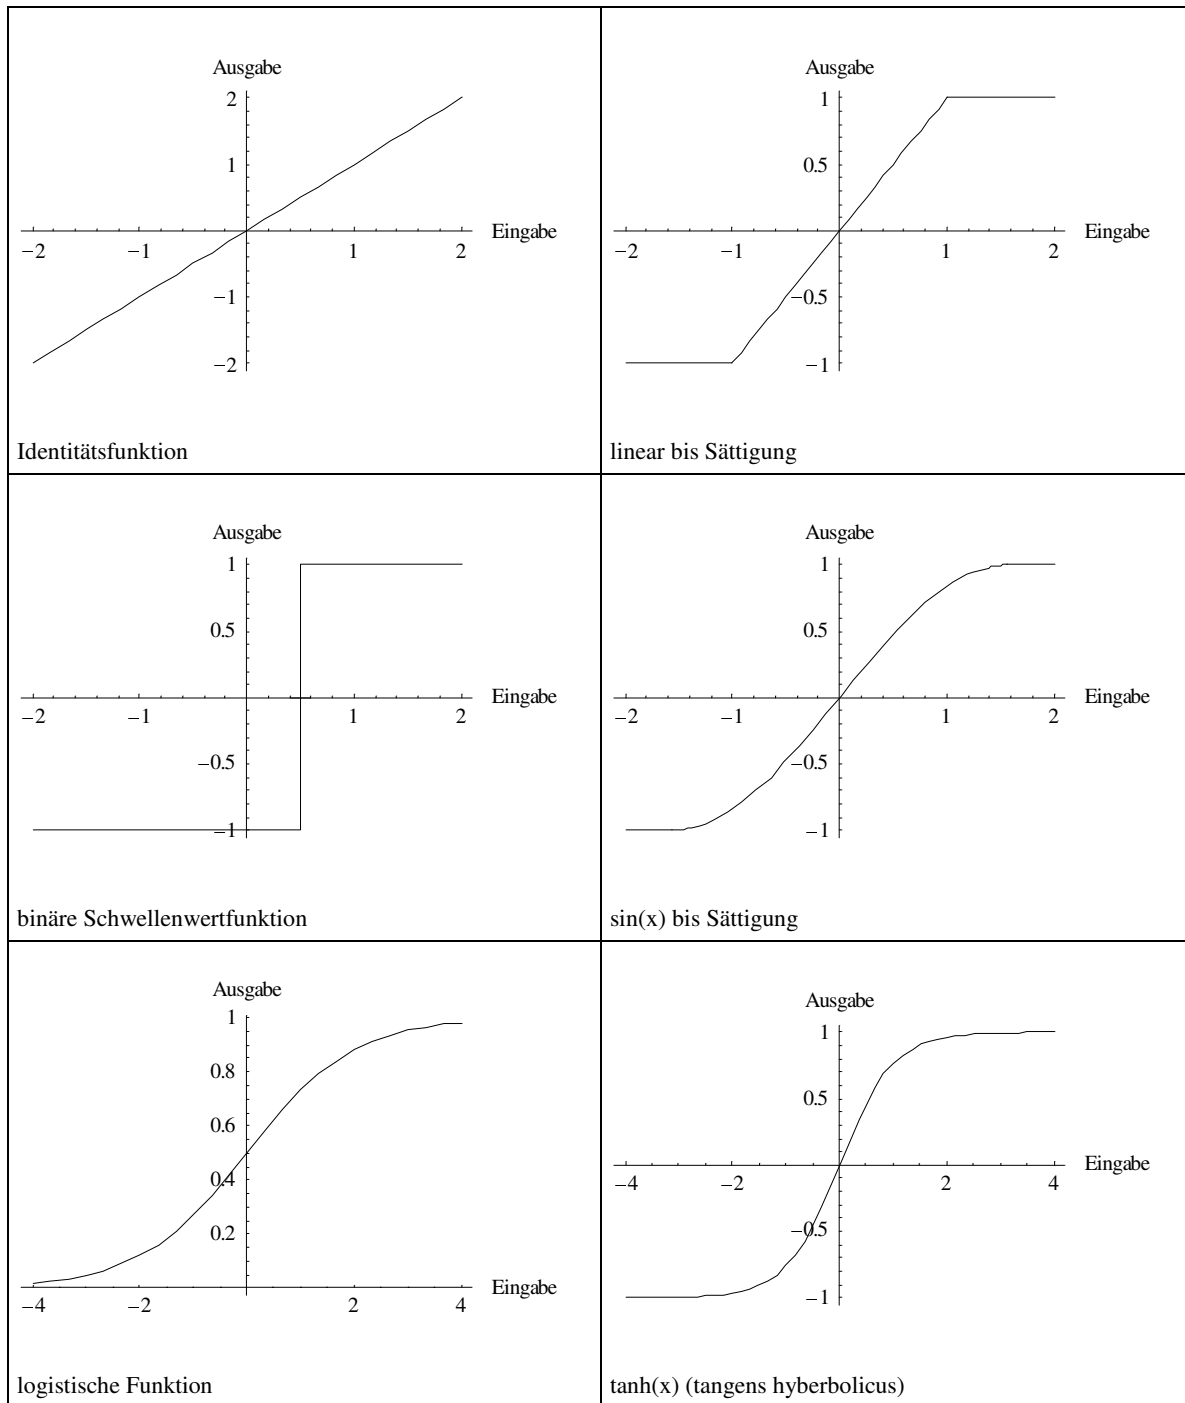
Außer der binären Aktivierungsfunktion gibt es noch eine Vielzahl weiterer gebräuchlicher, meist nichtlinearer Funktionen. Einige häufig verwendete Aktivierungsfunktionen sind in Bild 2.3 dargestellt. Auf der  $x$ -Achse ist jeweils der Eingangswert und auf der  $y$ -Achse der zugehörige Ausgabewert aufgetragen. Besonders häufig werden sigmoide (s-förmige) Aktivierungsfunktionen verwendet. Diese sind im Gegensatz zu den binären Funktionen stetig und überall differenzierbar. Die sigmoiden Aktivierungsfunktionen reagieren wesentlich sensibler bei kleinen Amplituden und haben ihre größte Steigung im Bereich des Schwellenwertes  $\Theta$ .



Durch die Einführung einer Ausgabefunktion  $f_{out}$  lässt sich das Modell eines Neurons erweitern. Die Ausgabe eines Neurons  $i$  wird dann durch die Ausgabefunktion  $f_{out}$  aus der Aktivierung der Neurons bestimmt. Es gilt dann:

$$y_i = f_{out} \left( f_a \left( \sum_j w_{ij} \cdot e_j - \Theta_i \right) \right). \quad (2.21)$$

Als weitere Ausgabefunktionen werden häufig die in Bild 2.3 dargestellten Funktionen verwendet. Es ist anzumerken, dass die Kombination von Aktivierungsfunktion und Ausgabefunktion meist auch wieder Aktivierungsfunktion genannt wird.



**Bild 2.3: Häufig verwendete Aktivierungs- und Ausgabefunktionen**

Schaltet man mehrere Neuronen hinter- oder nebeneinander, entsteht ein neuronales Netz. Bei der Topologie neuronaler Netze unterscheidet man zwischen Netzen mit und Netzen ohne Rückkopplung. Bei den Netzen ohne Rückkopplung (feedforward-Netze) existiert kein Pfad, der von einem Neuron direkt oder über zwischengeschaltete Neuronen wieder zu dem Neuron zurückführt. Bei den Netzen mit Rückkopplung unterschei-

det man die direkte Rückkopplung, die indirekter Rückkopplung, die Rückkopplung innerhalb einer Schicht und vollständig verbundene Netze.

Damit ein neuronales Netz funktionale Zusammenhänge abbilden kann, muss es trainiert werden bzw. es muss gegebene Aufgaben selbständig, anhand von Beispielen, erlernen. Im menschlichen Gehirn erfolgt das Lernen zum Teil durch die Änderung der Synapsenstärken. Schon 1949 stellte der Psychologe Donald O. Hebb die folgende Hypothese über das Lernen auf [Heb49]:

Die synaptische Eigenschaft (Verstärkung oder Hemmung) ändert sich proportional zum Produkt von prä- und postsynaptischer Aktivität.

Die meisten Lernverfahren für neuronale Netze beruhen auf dieser sogenannten Hebb'schen Lernregel. Unter dem Lernen neuronaler Netze wird meist die Modifikation der Verbindungsgewichte verstanden. Eine weitere Möglichkeit des Lernens ist die Änderung der Netzstruktur. Diese ist jedoch fast immer vorgegeben und sollte nicht mehr verändert werden. In der praktischen Anwendung unterscheidet man daher folgenden Arten des Lernens:

- Überwachtes Lernen (supervised learning),
- Unüberwachtes Lernen (unsupervised learning),
- Bestärkendes Lernen (reinforcement learning).

Beim überwachten Lernen gibt es einen externen Lehrer, der dem Netz zu einem vollständig spezifizierten Eingangsmuster das optimale Ausgabemuster präsentiert. Aufgabe des Lernverfahrens ist es, die Gewichte des Netzes so zu ändern, dass das Netz nach wiederholter Präsentation der Ein- und Ausgabemuster diese Assoziation selbständig vornehmen und auch für unbekannte Eingangsmuster generalisieren kann.

Beim unüberwachten Lernen werden dem Netz nur Eingabemuster präsentiert. Durch das Lernverfahren versucht das Netz ähnliche Muster in ähnliche Kategorien zu klassifizieren. Bekannte Anwendungen dieses Lernverfahrens sind die selbstorganisierenden Karten von Kohonen.

Beim verstärkenden Lernen gibt ein Trainer zu jedem Eingabemuster der Trainingsmenge nur an, ob es richtig oder falsch klassifiziert wurde, jedoch nicht die korrekte Ausgabe- bzw. Zielwerte der einzelnen Ausgabeneuronen. Das Netz muss die korrekten Ausgaben selbst finden.

### 2.3.4 Arten Neuronaler Netze

Im Folgenden sollen einige für die praktische Anwendung besonders bedeutsame Arten und Architekturen von Neuronalen Netzen kurz beschrieben werden.

#### **Multi Layered Perceptron**

Ein Multi Layered Perceptron (MLP) ist ein Neuronales Netz, das aus mehreren Schichten aufgebaut ist. Es besitzt eine Eingabeschicht aus Eingabeneuronen, eine oder mehrere verdeckte Schichten von Neuronen und eine Ausgabeschicht. Die Neuronen in einem solchen Feedforward-Netz sind jeweils nur mit Neuronen der folgenden Schicht verbunden. Es existiert also keine Rückkopplung. Die MLP-Netze sind sehr mächtige Netze und vielseitig einsetzbar. In [Cyb89] wurde gezeigt, dass mit einem 3-schichtigen vorwärtsgerichteten Netz mit einer ausreichenden Anzahl von verdeckten Neuronen jede beliebige stetige Funktion approximiert werden kann.

#### **Jordan-Netze und Elman-Netze**

Jordan- und Elman-Netze sind partiell rekurrente Netzarchitekturen. Sie eignen sich besonders zur Erkennung und Klassifizierung zeitveränderlicher Muster und für die Prognose von Zeitreihen [Zel00]. Die partiell rekurrenten Netze sind aus den vorwärtsgerichteten Netze abgeleitet, besitzen jedoch Rückkopplungsschleifen mit sogenannten Kontextzellen. Die Kontextzellen dienen hierbei als Speichermechanismus. Die Ausgabe des Netzes hängt dann nicht nur von der aktuellen Eingabe, sondern auch von vorangegangenen Eingaben ab. Eine ausführliche Darstellung dieser Netze findet man in [Zel00].

#### **Selbstorganisierende Karten**

Bei den selbstorganisierenden Karten handelt es sich um einschichtige neuronale Netze mit einer Schicht aktiver Neuronen. Die selbstorganisierenden Karten werden mit unüberwachten Lernverfahren trainiert. Die Neuronen dieser Netze arbeiten immer kollektiv zusammen und sind über Rückkopplungen miteinander verbunden. Das heißt werden Neuronen im Lernprozess aktiviert, so werden auch benachbarte Neuronen mitverstärkt. Das Modell eignet sich besonders zur Visualisierung und Auffindung von Ähnlichkeitsbeziehungen in einem hochdimensionalen Eingaberaum.

#### **Hopfield Netze**

Die Hopfield Netze sind rekurrente Netzwerke, die jedoch nur indirekte Rückkopplung besitzen, d.h. die Neuronen eines Hopfield-Netzes sind alle untereinander vernetzt. Die Hopfield-Netze lassen sich für die Mustererkennung und für Optimierungsprobleme einsetzen.

### **Boltzmann-Maschine**

Die Boltzmann-Maschine ist eine Weiterentwicklung der Hopfield-Netze. Die Neuronen ändern ihre Zustände jedoch nicht deterministisch sondern zufällig nach einer Wahrscheinlichkeitsverteilung. Als Lernverfahren wird bei der Boltzmann-Maschine das sogenannte simulierte Kühlen (simulated annealing) verwendet.

### **Radiale-Basisfunktion-Netze**

Die Radiale-Basisfunktion-Netze (RBF-Netze) sind eine besondere Art von vorwärtsgerichteten neuronalen Netze. Sie besitzen nur eine verdeckte Schicht von Neuronen mit speziellen radialsymmetrischen Aktivierungsfunktionen. Die Netze eignen sich zur Approximation von mehrdimensionalen funktionalen Zusammenhängen.

### **Adaptive Resonance Theory (ART)**

Bei den ART-Netzen handelt es sich um eine Familie von Netzen. Eine Eigenschaft dieser Netze ist es, dass sie beim Lernen neuer Assoziation, bisher gelernte Assoziationen nicht vergessen. Sie lösen damit das Stabilitäts-Plastizitäts-Dilemma anderer Netztypen. Dieser Vorteil wird jedoch durch eine erhebliche Komplexität erkaufte [Hof93].

### **Neocognitron**

Das Neocognitron ist ein hierarchisches vorwärtsgerichtetes Netzwerk, bestehend aus verschiedenen Stufen von Neuronen. Das Neocognitron wird vor allem zur Erkennung visueller Muster eingesetzt. Als Vorbild dient das visuelle System von Säugetieren. Die Netze sind in der Lage bis zu einem bestimmten Grad auch verzerrte und deformierte Muster zu erkennen.

### **Time-Delay-Netze**

Die Time-Delay-Netze sind ebenfalls vorwärtsgerichtete Netze, die speziell zur automatischen Spracherkennung entwickelt wurden. Die Netze sind in der Lage, zeitlich veränderliche Muster an unterschiedlichen Positionen und mit unterschiedlicher Länge zu erkennen. Die Time-Delay-Netze können auch für andere Fragestellungen, wie beispielsweise Prognosen genutzt werden.

### 3 Untersuchte Systeme

Die Forderungen nach erhöhter Sicherheit und Komfort führen zu einem ständig steigenden Anteil der Elektronik im Kraftfahrzeug. Durch die Zunahme der Funktionalität und Vielfalt der Varianten, wächst die Komplexität eines Fahrzeugs stetig. Zur Beherrschung der steigenden Komplexität werden neue Systeme daher zunehmend modular aufgebaut und die Kommunikation der Systeme untereinander wird auf logisch und physikalisch standardisierte Weise erfolgen [Dai02]. Es wird zu einer starken Vernetzung der Systeme kommen, bei denen die Bussysteme, Betriebssysteme und Applikationen intelligent miteinander verknüpft werden müssen. Ursprünglich rein mechanische Grundkonzepte werden zunehmend durch mechatronische Systeme ersetzt. Unter Mechatronik versteht man die Verknüpfung von mechanischen, elektronischen und datenverarbeitenden Komponenten in einem System. Beispiele für mechatronische Systeme im Kraftfahrzeug sind das Motormanagement, das Anti-Blockier-System (ABS), die Antriebsschlupfregelung (ASR), die Fahrdynamik-Regelung (FDR) und das Lenksystem. Laut der Studie „Automobiltechnologie 2010“ wird der Wertanteil der Elektrik und Elektronik im Mittel über alle Fahrzeuge von 22% im Jahr 2000 auf ca. 35% im Jahr 2010 ansteigen [Mer01]. Die Schwerpunkte bilden dabei nach einer Studie der Society of Automotive Engineers (SAE) und DuPont die Sicherheitssysteme mit 65% gefolgt von Telematik- und Kommunikationssystemen mit 27,4% und Unterhaltungselektronik mit 17,9% (zitiert nach [Pon02]). Als wichtigste Faktoren für die Neuentwicklung von Elektrik- und Elektroniksystemen werden die Kosten mit 34,6% und nahezu gleichwertig die Zuverlässigkeit mit 33% genannt.

Letzteres macht noch einmal die große Bedeutung von frühzeitigen Zuverlässigkeitsprognosen für Komponenten und Baugruppen deutlich.

In Bild 3.1 ist eine Übersicht für zukünftige Entwicklungen im Kraftfahrzeugbereich dargestellt. Es ist zu erwarten, dass nahezu jedes System eine eigene Aktuatorik und Steuereinheit besitzen wird. Auf Grund dessen werden für die Untersuchungen im Rahmen dieser Arbeit u.a. elektronische Stellmotoren, Steuergeräte und weitere komplexe Baugruppen ausgewählt.

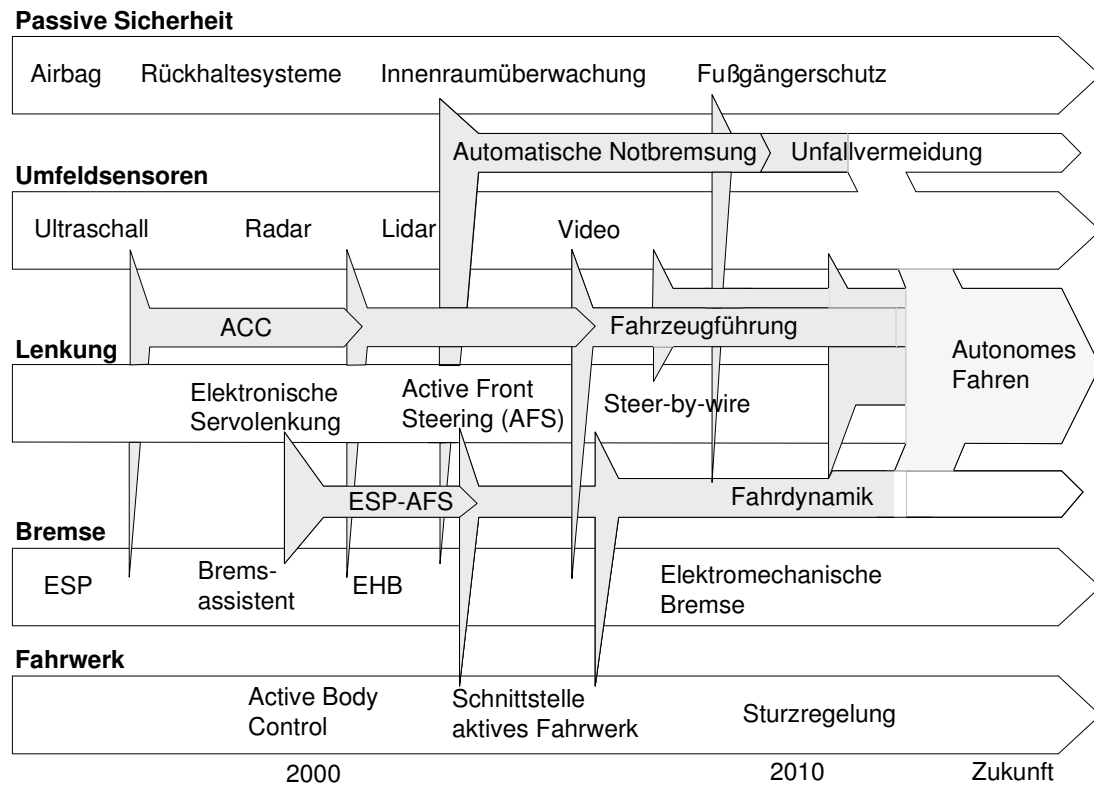


Bild 3.1: Roadmap zukünftiger Entwicklungen im Automobilbereich nach [Pro02]

### 3.1 Wischsysteme


Gutes Sehen bei allen Wetterbedingungen ist eine zentrale Anforderung an die Fahr-sicherheit. Die Voraussetzung dafür sind einwandfrei funktionierende Scheibenwischer. Aus diesem Grund ist die Bewertung der Zuverlässigkeit von Wischeranlagen von be-sonderem Interesse. Eine Wischeranlage besteht im Regelfall aus den Einzelkomponen-ten [Sch93]:

- Antriebsmotor,
- Gelenkstange,
- Wischerlager,
- Wischerarme,
- Wischerblätter.

Die Gestaltung der Antriebseinheit (Motor, Gestänge und Wischerlager) erfolgt wei-testgehend fahrzeugspezifisch. Bei den Wischermotoren unterscheidet man nach der Bewegungsart der Antriebswelle [Wei89] zwischen

- Pendelwischermotoren und
- Umlaufwischermotoren.


Als Antriebsmotoren werden meist kleine Elektromotoren verwendet. Das Erregerfeld wird von einer im Nebenschluss geschalteten elektrischen Spule oder von einem Dauermagneten aufgebaut. Durch ein dem Motor nachgeschaltetes Getriebe wird die erforderliche Drehzahl und das notwendige Drehmoment erreicht. Bild 3.2 zeigt den schematischen Aufbau eines Wischermotors mit Schneckengetriebe.



**Bild 3.2: Wischermotor mit Schneckenantrieb (Schema) [Bsc98]**


Zukünftige Entwicklungen von Wischsystemen verzichten auf das Gestänge und setzen zwei separate Elektromotoren für den Antrieb der Wischerarme ein. Die Systeme zeichnen sich durch einen geringeren Bauraum und geringeres Gewicht aus. Außerdem lassen sich durch den Aufbau mit zwei unabhängigen Antrieben neue Funktionen realisieren. Bild 3.3 zeigt beispielsweise den Aufbau eines gestängelosen Wischsystems im Vergleich zu den bisherigen Systemen.





**Bild 3.3: Wischerkonzept mit und ohne Gestänge (Foto: Bosch)**

Die folgende Abbildung zeigt den prinzipiellen Aufbau und die Bestandteile eines Gleichstrommotors (Bild 3.4). Gleichstrommotoren, wie die Wischermotoren, werden häufig mit leichten Modifikationen auch in andere Systeme im Kraftfahrzeug als elektrische Antriebe eingebaut. Sie spielen daher eine besondere Rolle bei der Zuverlässigkeitsprognose von Komponenten und Baugruppen im Kraftfahrzeug. Der feststehende Teil eines Gleichstrommotors nennt man Ständer oder Stator, der sich drehende Teil Läufer. Der Läufer wird häufig auch als Anker bezeichnet und trägt die Ankerwicklung, die an den Kollektor angeschlossen ist. Auf den Kollektorlamellen schleifen die feststehenden Bürsten, über die der Ankerwicklung ein Ankerstrom zugeführt wird. Durch den in der Ankerwicklung fließenden Strom entsteht ein Magnetfeld, das das Hauptfeld des Stators senkrecht durchsetzt und ein entsprechendes Drehmoment erzeugt.



**Bild 3.4: Aufbau Gleichstrommotor**

Für neue Antriebe im Kraftfahrzeug werden häufig auch bürstenlose, elektronisch kommutierte Motoren (BLDC) eingesetzt. Diese Motoren besitzen im Gegensatz zu den Vorgängern eine kürzere Einbaulänge, einen höheren Wirkungsgrad und eine längere zu erwartende Lebensdauer, da keine Bürstenabnutzung stattfindet. Durch neue Fertigungsverfahren und kleinere elektronische Komponenten lässt sich eine immer höhere Integration der Elektronik erzielen. Dadurch können immer mehr elektronische Funktionen direkt in den Elektromotor integriert werden. So ermöglicht die in die neue Generation von bürstenlosen Motoren integrierte Elektronik eine kontinuierliche Regelung des Motors. In ein Fahrzeug der Oberklasse werden zur Zeit bis zu 100 verschiedene Elektromotoren eingebaut. Diese Zahl macht deutlich, wie wichtig es ist, die Zuverlässigkeit von Elektromotoren prognostizieren zu können.

## 3.2 Kupplungsteller

Das automatisierte Schaltgetriebe (ASG) bietet einen ähnlichen Komfort wie ein Automatikgetriebe. Es ist jedoch hinsichtlich Kosten und Gewicht günstiger und erreicht einen niedrigeren Kraftstoffverbrauch. Bei einem automatisierten Schaltgetriebe betätigen Elektromotoren, gesteuert von einer zentralen Elektronik, die Kupplung und ersetzen den manuellen Schaltvorgang. In Bild 3.5 ist der schematische Aufbau eines auto-

matisierten Schaltgetriebes mit einem Kupplungsteller dargestellt. Der Kupplungsteller ist in dem Bild als „Intelligenter Aktor“ bezeichnet.

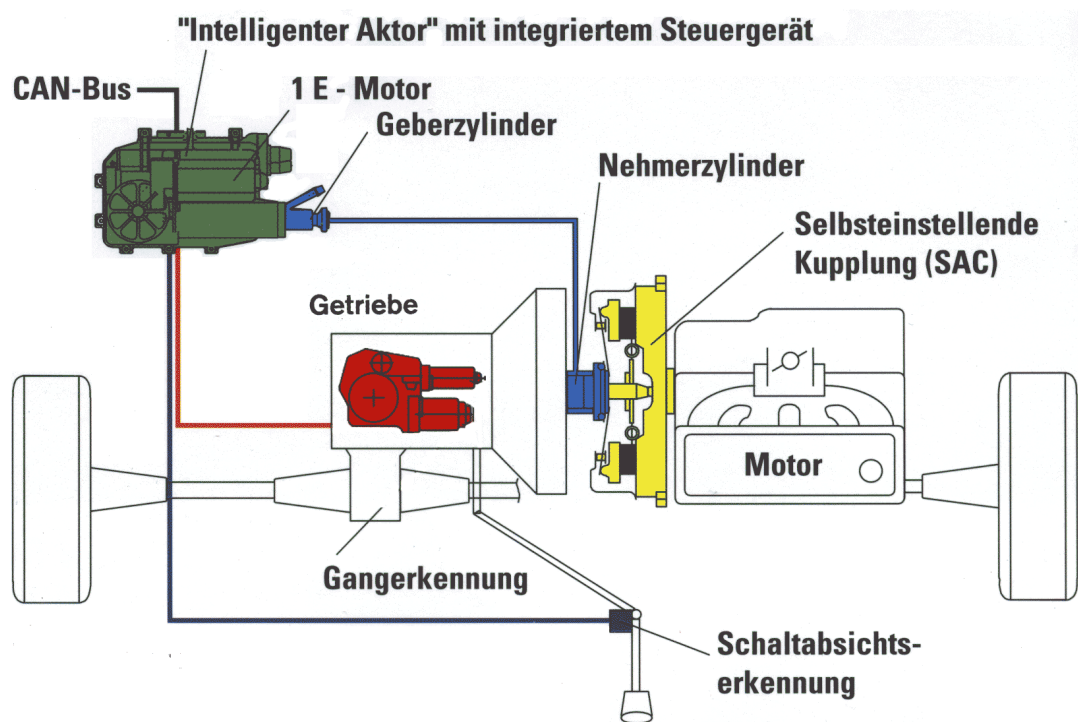


Bild 3.5: Aufbau eines automatisierten Schaltgetriebes (ASG) (nach Bild: LuK)

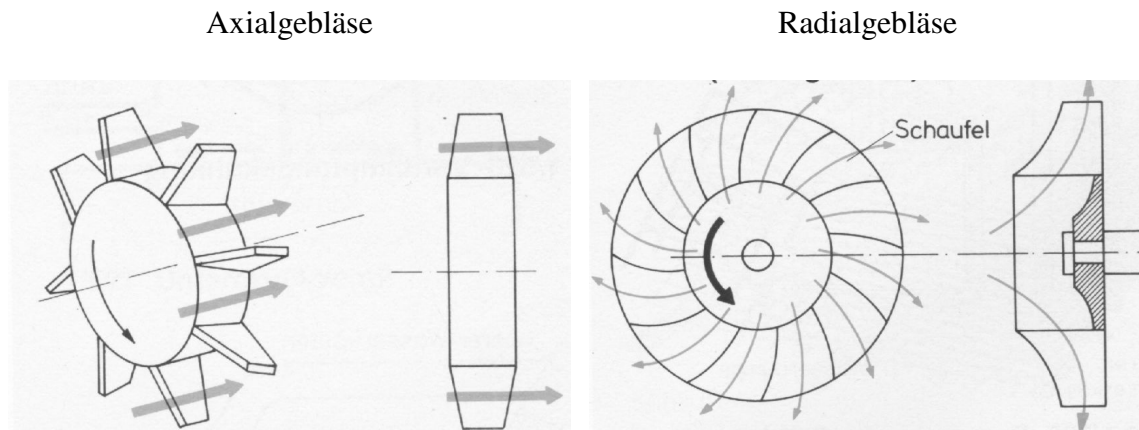
Der Kupplungsteller ist ein hochintegriertes System, das sich im Wesentlichen aus Standardkomponenten zusammensetzt. Er ist daher ein gutes Beispiel dafür, wie Analyseergebnisse von Grundkomponenten, wie Elektromotoren, für die Bewertung komplexerer Systeme genutzt werden können.

### 3.3 Motorkühlgebläse

Motoren, die nicht direkt im Fahrtwind liegen und Mehrzylindermotoren lassen sich durch die Gebläseluftkühlung kühlen. Der Gebläseluftstrom verhindert eine Überhitzung des Motors auch bei stehendem Fahrzeug und bei niedriger Geschwindigkeit [Wel89].

Unter einem Gebläsemodul versteht man eine fertig montierte Einheit, bestehend aus Antriebsmotor, Lüfter und Zarge. Die Gebläsedrehzahl lässt sich stufenlos über ein in die Zarge integriertes Steuergerät oder in Stufen über integrierte Vorwiderstände regeln. Bei den Gebläsen unterscheidet man zwischen Axialgebläse und Radialgebläse. Die Axialgebläse saugen Kühlluft in Achsrichtung an und drücken diese in Achsrichtung

weiter. Radialgebläse saugen Kühlluft ebenfalls in Achsrichtung an, drücken diese jedoch radial weiter. Man nennt sie deshalb auch Zentrifugal-, Kreisel-, oder Schleuder-gebläse. Bild 3.6 zeigt die Funktionsweise eines Axial- und Radialgebläses.



**Bild 3.6: Vergleich Funktionsweise Axial- und Radialgebläse [Wei89]**

Steuergeräte werden in heutige und zukünftige Systeme oft direkt integriert, so dass viele Systeme eine eigene, selbständige Rechen- und Regelungseinheit besitzen. Die Komplexität der Steuergeräte ist dabei oft sehr unterschiedlich. Sie reichen von einfachen Reglern, bis hin zu sehr komplexen Strukturen, mit integrierten Sensoren und mehreren Mikrocontrollern. Die Regelung der untersuchten Motorkühlgebläse erfolgt über ein in die Zarge integriertes Steuergerät. Bei den Motorkühlgebläsen wurden während der Garantiezeit u.a. Ausfälle dieser Steuergeräte registriert. Die Steuergeräte wurden daher beispielhaft als Subsystem des Motorkühlgebläses für die folgenden Analysen ausgewählt.

## **4 Allgemeines Zuverlässigkeitsprognosemodell**

Bei der Analyse verschiedener Komponenten und Baugruppen im Kraftfahrzeug hat sich gezeigt, dass es notwendig ist, neue individuelle Ansätze für die Zuverlässigkeitsprognose zu entwickeln. Das Ausfallverhalten von mechanischen, elektronischen oder elektromechanischen Systemen ist oft von verschiedenen Fehlermechanismen geprägt, die sich in einem charakteristischen Ausfallratenverlauf widerspiegeln. Auf Grund dessen, ist es wichtig generelle Ansätze zu entwickeln, die es erlauben, das Ausfallverhalten beliebiger Kfz-Komponenten zu modellieren. Unter einem allgemeinen Zuverlässigkeitsprognosemodell soll ein übergeordnetes, generalisiertes Modell verstanden werden, aus dem sich verschiedene praxisrelevante Modellvarianten ableiten lassen. Im Folgenden werden einige wichtige Ausfallmodelle eingeführt und daraus ein allgemeines Modell für die Analyse entwickelt. Auf Basis dieses neuen allgemeinen Ausfallmodells wird der Aufbau und Ablauf der Zuverlässigkeitsprognose dargestellt. Im Anschluss werden die Prognoseergebnisse für verschiedene Kfz-Komponenten und die dafür individuell entwickelten Ausfallmodelle erläutert. Des Weiteren wird beispielhaft eine praktische Abschätzung der Kostenänderung bei Garantiezeitverlängerungen und des zu erwartenden Ersatzbedarfs eines Produktes durchgeführt.

### **4.1 Ausfallmodelle**

Die Komponenten und Baugruppen von Kraftfahrzeugen sind verschiedensten Belastungen und Beanspruchungen innerhalb ihrer Lebensdauer ausgesetzt. Um das spezifische Ausfallverhalten dieser Komponenten charakterisieren zu können, werden nun einige wichtige Ausfallmodelle kurz vorgestellt. Die Wahl eines geeigneten Ausfallmodells, zur Beschreibung der Zuverlässigkeit, hängt im Wesentlichen von der individuellen Fragestellung und der gewünschten Aussagegenauigkeit ab. Das entwickelte Modell sollte dabei so einfach wie möglich und nur so detailliert wie nötig sein.

#### **4.1.1 Unimodales Ausfallmodell**

Das unimodale Ausfallmodell ist eines der wichtigsten Ausfallmodelle überhaupt. Es wird bei den meisten statistischen Auswertungen verwendet und hat damit eine große praktische Bedeutung. Ein wesentlicher Grund hierfür ist die Einfachheit des Modells, da das gesamte Ausfallverhalten mit Hilfe einer Verteilungsfunktion approximiert wird.

Dieses Modell lässt sich vor allem dann verwenden, wenn es sich um eine homogene Grundgesamtheit handelt, die über einen begrenzten Zeitraum untersucht wird und dabei ein charakteristisches Ausfallverhalten zeigt. Bei der statistischen Auswertung von Garantiedaten sollte immer versucht werden, ein solches Modell zu Grunde zu legen. Die Zuverlässigkeitskenngrößen eines unimodalen Ausfallmodells entsprechen den in Kapitel 2.2.1 in Tabelle 2.1 dargestellten Zusammenhängen und sollen hier nicht erneut aufgeführt werden. Das unimodale Ausfallmodell wurde u.a. für die Analyse von ABS-Steuergeräten verwendet [Pau98].

#### 4.1.2 Mischpopulations-Ausfallmodell

Eine Mischpopulation ist eine Grundgesamtheit  $n$ , die sich aus  $r$  verschiedenen Subpopulationen, mit unterschiedlichen Ausfallverhalten zusammensetzt. In der Praxis kommen solche Mischpopulationen häufig vor. Mögliche Ursachen können beispielsweise unterschiedliche Fertigungsmaschinen, verschiedene Einbauorte oder unterschiedliche Umgebungsbedingungen sein. Ein Mischpopulations-Ausfallmodell (multimodal) wird man jedoch nur wählen, wenn das Ausfallverhalten der Subpopulationen erkennbar unterschiedlich ist. Das Ausfallverhalten jeder identifizierten und separierten Subpopulation wird durch eine eigene Lebensdauervertelung beschrieben. Die Zuverlässigkeitskenngrößen eines Mischpopulationsmodells, mit  $n = n_1 + n_2 + \dots + n_r$ , lassen sich wie folgt bestimmen:

**Tabelle 4.1: Zuverlässigkeitskenngrößen Mischpopulations-Ausfallmodell**

Kenngröße	Formel
Überlebenswahrscheinlichkeit	$R(t) = \frac{n_1}{n} R_1(t) + \frac{n_2}{n} R_2(t) + \dots + \frac{n_r}{n} R_r(t)$
Ausfallwahrscheinlichkeit	$F(t) = \frac{n_1}{n} F_1(t) + \frac{n_2}{n} F_2(t) + \dots + \frac{n_r}{n} F_r(t)$
Ausfalldichte	$f(t) = \frac{n_1}{n} f_1(t) + \frac{n_2}{n} f_2(t) + \dots + \frac{n_r}{n} f_r(t)$
Ausfallrate	$h(t) = \frac{\frac{n_1}{n} f_1(t) + \frac{n_2}{n} f_2(t) + \dots + \frac{n_r}{n} f_r(t)}{\frac{n_1}{n} R_1(t) + \frac{n_2}{n} R_2(t) + \dots + \frac{n_r}{n} R_r(t)}$

Mittlere Lebensdauer	$E(T) = \frac{n_1}{n} \int_0^{\infty} R_1(t) dt + \frac{n_2}{n} \int_0^{\infty} R_2(t) dt + \dots + \frac{n_r}{n} \int_0^{\infty} R_r(t) dt$
----------------------	--

### 4.1.3 Konkurrierendes Ausfallmodell

Die Grundidee des konkurrierenden Ausfallmodells ist, dass eine Komponente oder Baugruppe auf Grund verschiedener Ursachen zu jedem beliebigen Zeitpunkt ausfallen kann. Das Modell wird häufig auch als „competing -model“ bezeichnet. Jede dieser Ausfallmöglichkeiten wird durch eine eigene Wahrscheinlichkeitsverteilungen beschrieben, wobei die Ausfallursachen voneinander unabhängig sind. Es sollte auch bei diesem Modell versucht werden, möglichst wenige Verteilungsfunktionen zu verwenden, um die Zahl der unbekannt Parameter im Modell so gering wie möglich zu halten. Zur Durchführung einer Zuverlässigkeitsanalyse mit dem konkurrierenden Ausfallmodell müssen die einzelnen Fehler unterscheidbar sein, d.h. die Daten müssen auf Grund ihrer Ausfallursachen separiert werden können. Für jede identifizierte Ausfallursache wird dann eine individuelle Datenanalyse durchgeführt. Das Gesamtausfallverhalten der Grundgesamtheit lässt sich entsprechend durch Kombination der ermittelten Wahrscheinlichkeitsverteilungen beschreiben. Die Zuverlässigkeitskenngrößen für das Ausfallmodell mit  $r$  Ausfallarten sind wie folgt definiert:

**Tabelle 4.2: Zuverlässigkeitskenngrößen Konkurrierendes Ausfallmodell**

Kenngröße	Formel
Überlebenswahrscheinlichkeit	$R(t) = R_1(t) \cdot R_2(t) \cdot \dots \cdot R_r(t)$
Ausfallwahrscheinlichkeit	$F(t) = 1 - (1 - F_1(t))(1 - F_2(t)) \cdot \dots \cdot (1 - F_r(t))$
Ausfalldichte	$\begin{aligned} f(t) &= - \frac{d(R_1(t) \cdot R_2(t) \cdot \dots \cdot R_r(t))}{dt} \\ &= - \frac{dR_1(t)}{dt} R_2(t) \cdot \dots \cdot R_r(t) - \frac{dR_2(t)}{dt} R_1(t) \cdot R_3(t) \cdot \dots \cdot R_r(t) \\ &\quad - \frac{dR_r(t)}{dt} R_1(t) \cdot R_2(t) \cdot \dots \cdot R_{r-1}(t) \end{aligned}$

Ausfallrate	$h(t) = -\frac{dR_1(t)}{R_1(t) dt} - \frac{dR_2(t)}{R_2(t) dt} - \dots - \frac{dR_r(t)}{R_r(t) dt} = h_1(t) + h_2(t) + \dots + h_r(t)$
Mittlere Lebensdauer	$E(T) = \int_0^{\infty} R_1(t) \cdot R_2(t) \cdot \dots \cdot R_r(t) dt$

#### 4.1.4 Teilpopulations-Ausfallmodell

Das Teilpopulations-Ausfallmodell beschreibt das Ausfallverhalten einer Teilpopulation innerhalb der Grundgesamtheit. Es handelt sich hierbei um eine spezielle Form des Mischpopulations-Ausfallmodells, wobei jedoch nur eine Subpopulation betrachtet wird. Die Restpopulation fällt nach diesem Modell innerhalb einer endlichen Zeitspanne nicht aus, d.h. sie ist resistent bzw. immun gegenüber der Ausfallursache. Nach Meeker wird das Teilpopulations-Ausfallmodell auch „limited failure population model“ (LFP) genannt [Mee98]. Wie der Name schon sagt, ist die Grundgesamtheit hinsichtlich möglicher Ausfälle beschränkt. Wird ein Teilpopulations-Ausfallmodell für eine Analyse verwendet, bedeutet dies jedoch eine erhebliche Einschränkung und kann zu verfälschten Ergebnissen führen. Es ist daher wichtig, vorab zusätzliche Informationen über die Ausfallmechanismen zu sammeln und die Annahmen für ein solches Modell zu überprüfen.

Das Teilpopulations-Ausfallmodell eignet sich besonders zur Beschreibung fertigungsbedingter Fehler, die häufig nur eine begrenzte Fertigungscharge betreffen. Es gibt zahlreiche Beispiele, bei denen ein Teilpopulations-Ausfallmodell erfolgreich angewendet wurde. Meeker setzte das Modell für die Analyse von IC's ein. Er untersuchte hierzu in [Mee87] die Testdaten aus Lebensdauerversuchen. Ein wesentlicher Vorteil des Modells ist es, dass der Umfang der betroffenen Subpopulation schon geschätzt werden kann, bevor diese ausgefallen sind. Das Modell wurde auch für die Auswertung von medizinischen Tests, unter Verwendung einer zusätzlichen erklärenden Variablen, eingesetzt [Far77]. Anscombe verwendete ein LFP-Modell für exponentiell verteilte Ereignisse in der Marktforschung [Ans61]. In [Far82] wurde die Analyse toxikologischer Experimente mit Hilfe eines solchen Modells durchgeführt. Eine Vielzahl weiterer Veröffentlichungen, wie [Blu75, Mal77, Ste81, Llo79], zeigen die praktische Relevanz und die Anwendbarkeit des Modells in verschiedensten Bereichen.



Bei dem Teilpopulations-Ausfallmodell geht man davon aus, dass nur ein Anteil  $w$  der Grundgesamtheit für eine bestimmte Ausfallursache anfällig ist. Die nicht betroffene Restpopulation vom Anteil  $(1-w)$  wird innerhalb einer endliche Zeitspanne, z.B. der technischen Betriebsdauer, nicht ausfallen. Im Weiteren sollen alle mit dem Index  $T$  gekennzeichneten Größen die betroffene Teilpopulation beschreiben. Ein zufällig aus der Grundgesamtheit ausgewähltes Produkt wird demnach eine Ausfallwahrscheinlichkeit von  $P(T \leq t) = w \cdot F_T(t)$  besitzen, wobei  $F_T(t)$  die Ausfallwahrscheinlichkeit der Teilpopulation wiedergibt. Eine Übersicht der Zuverlässigkeitskenngrößen für das Ausfallmodell ist im Folgenden dargestellt:

**Tabelle 4.3: Zuverlässigkeitskenngrößen Teilpopulations-Ausfallmodell**

Kenngröße	Formel
Überlebenswahrscheinlichkeit	$R(t) = (1 - w) + w \cdot R_T(t)$
Ausfallwahrscheinlichkeit	$F(t) = w \cdot F_T(t)$
Ausfalldichte	$f(t) = w \cdot f_T(t)$
Ausfallrate	$h(t) = \frac{w \cdot f_T(t)}{(1 - w) + w \cdot R_T(t)}$
Mittlere Lebensdauer	$E(T) = w \cdot \int_0^{\infty} t \cdot f_T(t) dt$

#### 4.1.5 Verallgemeinertes Ausfallmodell

Um beliebige Kfz-Komponenten mit beliebigem Ausfallverhalten analysieren zu können, ist es notwendig, ein allgemeines Ausfallmodell zu entwickeln. Dieses muss in der Lage sein, verschiedene Fehlermechanismen mit unterschiedlichem zeitlichen Verhalten zu beschreiben. Das verallgemeinerte Ausfallmodell ist eine Weiterentwicklung des Mischpopulations-Ausfallmodells auf Basis von konkurrierenden Ausfallursachen. Geht man davon aus, dass eine Baugruppe oder Komponente auf Grund mehrerer Fehlerursa-

chen zu jedem Zeitpunkt ausfallen kann, lässt sich ein übergeordnetes konkurrierendes Modell erstellen. Es gilt also:

$$F(t) = 1 - (1 - F_1(t))(1 - F_2(t)) \cdot \dots \cdot (1 - F_r(t)), \quad (4.1)$$

mit  $r$  verschiedenen Ausfallmöglichkeiten.

Treten nun manche Ausfallmechanismen nur innerhalb einer Teilpopulation auf, so lässt sich dies durch ein eingebettetes Teilpopulations-Ausfallmodell für die entsprechende Fehlermöglichkeit modellieren. Bestehen beispielsweise für eine Komponente zwei Fehlerursachen, wobei die erste nur bei einem Anteil  $w$  der Grundgesamtheit auftreten kann, lässt sich die Überlebenswahrscheinlichkeit wie folgt formulieren:

$$R(t) = ((1 - w) + w \cdot R_1(t)) \cdot R_2(t), \quad (4.2)$$

mit  $w$ : Anteil der betroffenen Teilpopulation,

$R_1(t)$ : Überlebenswahrscheinlichkeit Fehlerursache 1,

$R_2(t)$ : Überlebenswahrscheinlichkeit Fehlerursache 2.

Verallgemeinert man das erstellte Modell, so dass eine Ausfallursache für  $i$  Subpopulationen  $i$  verschiedene Auftretenswahrscheinlichkeiten besitzt, lässt sich mit Hilfe multimodaler Ausfallmodelle ein neues generalisiertes Ausfallmodell erstellen. Das entwickelte Modell besagt, dass ein Kfz-System auf Grund von  $r$  Fehlerursachen ausfallen kann, wobei jede Ausfallursache mit Hilfe von  $i$  verschiedenen Lebensdauerverteilungen entsprechend der  $i$  Subpopulationen beschrieben werden kann.


Die Zuverlässigkeitskenngrößen für das verallgemeinerte Ausfallmodell lassen sich, wie im Folgenden dargestellt, definieren. Alle zuvor beschriebenen Ausfallmodelle können als Sonderfälle des allgemeinen Modells betrachtet werden und lassen sich leicht aus diesem herleiten.

Tabelle 4.4: Zuverlässigkeitskenngrößen verallgemeinertes Ausfallmodell

Kenngröße	Formel
Überlebenswahrscheinlichkeit	$R(t) = \left( \sum_i w_{i1} R_{i1}(t) \right) \left( \sum_i w_{i2} R_{i2}(t) \right) \cdot \dots \cdot \left( \sum_i w_{ir} R_{ir}(t) \right)$
Ausfallwahrscheinlichkeit	$F(t) = 1 - \left( 1 - \sum_i w_{i1} F_{i1}(t) \right) \left( 1 - \sum_i w_{i2} F_{i2}(t) \right) \cdot \dots \cdot \left( 1 - \sum_i w_{ir} F_{ir}(t) \right)$
Ausfalldichte	$f(t) = - \frac{d \left[ \left( \sum_i w_{i1} R_{i1}(t) \right) \left( \sum_i w_{i2} R_{i2}(t) \right) \cdot \dots \cdot \left( \sum_i w_{ir} R_{ir}(t) \right) \right]}{dt}$
Ausfallrate	$h(t) = - \frac{d \left[ \left( \sum_i w_{i1} R_{i1}(t) \right) \left( \sum_i w_{i2} R_{i2}(t) \right) \cdot \dots \cdot \left( \sum_i w_{ir} R_{ir}(t) \right) \right]}{dt} \cdot \frac{1}{\left( \sum_i w_{i1} R_{i1}(t) \right) \left( \sum_i w_{i2} R_{i2}(t) \right) \cdot \dots \cdot \left( \sum_i w_{ir} R_{ir}(t) \right)}$
Mittlere Lebensdauer	$E(T) = \int_0^{\infty} \left( \sum_i w_{i1} R_{i1}(t) \right) \left( \sum_i w_{i2} R_{i2}(t) \right) \cdot \dots \cdot \left( \sum_i w_{ir} R_{ir}(t) \right) dt$

#### 4.1.6 Badewannenmodelle

Die Komponenten und Baugruppen durchleben während des Betriebs verschiedene Lebensphasen. Diese lassen sich mit Hilfe der sogenannten „Badewannenkurve“ veranschaulichen. Bild 4.1 zeigt schematisiert den Verlauf einer solchen Badewannekurve.



**Bild 4.1:** Verlauf Ausfallrate „Badewannenkurve“

Die Eigenschaft der Alterung einer Betrachtungseinheit ist unmittelbar aus dem Verlauf seiner Ausfallrate ablesbar. Eine konstante Ausfallrate bedeutet hierbei, dass die betrachteten Systeme keinem Alterungsprozess unterworfen sind, während eine wachsende Ausfallrate einer Alterung und eine sinkende Ausfallrate einer Verjüngung bei fortschreitender Zeit entspricht.

Der Verlauf der Kurve in Bild 4.1 zeigt, dass die Ausfallrate einer Betrachtungseinheit i.d.R. nicht nur eine dieser Tendenzen abdeckt, sondern sich über einen Zeitraum verändert. Die Kurve ist in drei Phasen einteilbar:

- Phase I: Frühausfälle mit rasch abnehmender Ausfallrate. Die Ausfälle sind meist auf Materialschwächen und Qualitätsschwankungen in der Fertigung oder auf Anwendungsfehler zurückzuführen,
- Phase II: Plötzliche und rein zufällige Ausfälle mit näherungsweise konstanter Ausfallrate. Ziel der Hersteller von technischen Erzeugnissen ist es, diese Phase möglichst lange zu gestalten (Nutzungsphase),
- Phase III: Verschleißausfälle (Spätausfallphase) mit ansteigender Ausfallrate. Die Ausfälle werden u.a. durch Alterung, Abnutzung und Ermüdung verursacht.

Die Dauer der einzelnen Phasen kann in der Praxis sehr stark variieren und hängt sowohl von der Beschaffenheit als auch von der Komplexität der Betrachtungseinheiten ab. Um das Ausfallverhalten von elektromechanischen Komponenten und Baugruppen im Kraftfahrzeug über die gesamte Lebensdauer beschreiben zu können, werden im

Folgenden drei spezielle Modellansätze zur Beschreibung von Badewannenkurven kurz vorgestellt.

Der einfachste, für praktische Anwendungen jedoch selten geeignete Ansatz, ist die Approximation der Badewannenkurve mit Hilfe einer einzigen Verteilungsfunktion. Diese muss mindestens einen Bereich mit monoton fallender und einen Bereich mit monoton steigender Ausfallrate aufweisen. Eine solche Verteilungsfunktion ist die Hjorth-Verteilung [Hjo80]. Die Ausfallrate der Hjorth-Verteilung mit den Parametern  $\alpha$ ,  $\beta$  und  $\gamma$  ist wie folgt definiert:

$$h(t) = \alpha t + \frac{\gamma}{1 + \beta t}. \quad (4.3)$$

Die Ausfallrate ist badewannenförmig für  $0 < \alpha < \beta\gamma$ .

Ein konkurrierendes Modell für die Beschreibung der Badewannenkurve wurde in [Gov82] vorgeschlagen. Für die zugehörige Ausfallrate mit sechs unbekanntem Parametern gilt:

$$h(t) = \lambda_1 e^{-\frac{5t}{t_1}} + \lambda_2 + \lambda_3 e^{\frac{t-t_2}{t_3}}, \quad (4.4)$$

mit  $t_1$ ,  $t_2$  und  $t_3$  sind Zeitkonstanten und  $\lambda_1$ ,  $\lambda_2$  und  $\lambda_3$  sind Basis-Ausfallraten. Für  $t = 0$  ist  $h(t=0) \approx \lambda_1 + \lambda_2$ , wobei die Ausfallrate  $\lambda_3$  wesentlich kleiner ist und für diesen Fall ignoriert werden kann. Für  $t_1 < t < (t_2 - 5t_3)$  kann der erste und dritte Term vernachlässigt werden und es finden nur zufällige Fehler mit einer Ausfallrate  $\lambda_2$  statt. Ab  $t > (t_2 - 5t_3)$  steigt der Verschleißanteil an und dominiert das Ausfallverhalten.

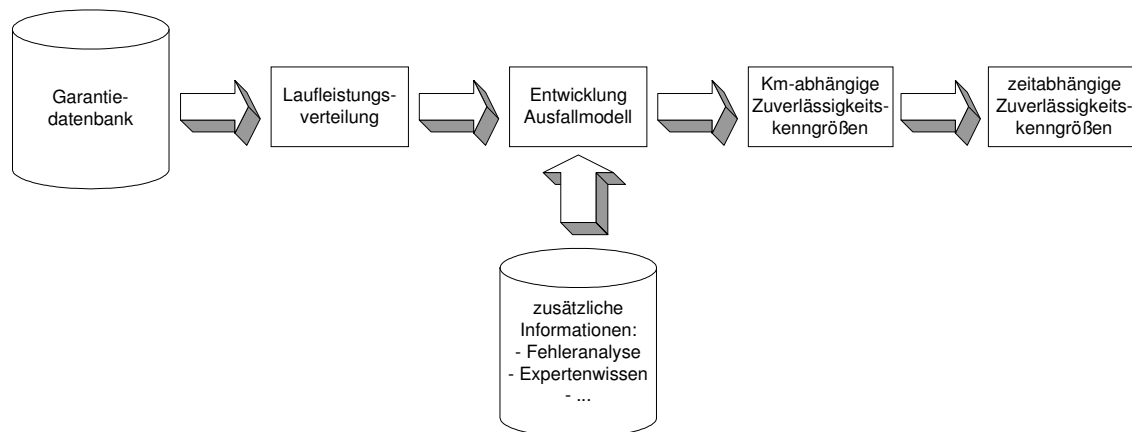
Eine weitere Möglichkeit zur Beschreibung einer Badewannenkurve stellt das Mischverteilungsmodell dar [Hah82, Kec71]. Dabei geht man davon aus, dass sich die Gesamtpopulation  $n$  in  $i$  gut separierbare Subpopulationen  $n_i$  einteilen lässt, deren Ausfallverhalten dann mit Hilfe einer Verteilungsfunktion beschrieben werden kann. Ein Mischverteilungsmodell mit drei Weibull-verteilten Subpopulationen hat folgende Form (siehe auch Mischpopulations-Ausfallmodell):

$$h(t) = \frac{\frac{n_1}{n} \alpha_1 \cdot \beta_1 \cdot t^{\beta_1-1} \cdot e^{-\alpha_1 t^{\beta_1}} + \frac{n_2}{n} \alpha_2 \cdot \beta_2 \cdot t^{\beta_2-1} \cdot e^{-\alpha_2 t^{\beta_2}} + \frac{n_3}{n} \alpha_3 \cdot \beta_3 \cdot t^{\beta_3-1} \cdot e^{-\alpha_3 t^{\beta_3}}}{\frac{n_1}{n} e^{-\alpha_1 t^{\beta_1}} + \frac{n_2}{n} e^{-\alpha_2 t^{\beta_2}} + \frac{n_3}{n} e^{-\alpha_3 t^{\beta_3}}}. \quad (4.5)$$

Die gegebene Ausfallrate beschreibt eine Badewannenkurve für  $\alpha_1 > \alpha_2 > \alpha_3$  und  $\beta_1 < 1$ ,  $\beta_2 = 1$  und  $\beta_3 > 1$ . Realistische Werte für die Formparameter bei Lebensdauerbetrachtungen sind beispielsweise  $\beta_1 = 0,5$ ,  $\beta_2 = 1$  und  $\beta_3 = 2$ .

## 4.2 Ablauf einer allgemeinen Zuverlässigkeitsprognose

Der im Folgenden dargestellte Ablauf der Zuverlässigkeitsprognose zeigt die einzelnen aufeinander folgenden Schritte, die zur Prognose der km- und zeitabhängigen Zuverlässigkeitskenngrößen notwendig sind. Das Grundgerüst des allgemeinen Zuverlässigkeitsprognosemodells ist das entwickelte allgemeine Ausfallmodell und das von Pauli in [Pau98] veröffentlichte 3-stufige Modell, das u.a. für die Analyse von ABS-Steuergeräten entwickelt und angewendet wurde. Durch die Kombination der beiden Ansätze ist es nun möglich, beliebige Komponenten und Baugruppen mit unterschiedlichem Ausfallverhalten zu analysieren. In Bild 4.2 sind die Analyseschritte einer allgemeinen Zuverlässigkeitsprognose dargestellt.



**Bild 4.2: Schritte des allgemeinen Zuverlässigkeitsprognosemodells**

Zunächst werden kurz die Voraussetzungen für eine Zuverlässigkeitsprognose erläutert und die benötigte Datenstruktur und Datenmenge beschrieben. Die Entwicklung eines individuellen Ausfallmodells ist von verschiedenen Faktoren abhängig. Es werden daher Anhaltspunkte und Entscheidungshilfen gegeben, die bei der Erstellung eines geeigneten Ausfallmodells unterstützen sollen. Im Anschluss wird die Vorgehensweise zur Berechnung der km- und zeitabhängigen Zuverlässigkeitskenngrößen beschrieben. Im Ergebnisteil werden exemplarisch einige ausgewählte Zuverlässigkeitsprognosen für verschiedene Kraftfahrzeug-Komponenten und -Baugruppen dargestellt und diskutiert sowie einige praktische Nutzungsmöglichkeiten für die gewonnen Ergebnisse gezeigt.

### 4.2.1 Voraussetzungen

Wie schon beschrieben, ist die Zuverlässigkeitsprognose auf Basis von Garantiedaten ein Bestandteil eines umfassenden Sicherheits- und Zuverlässigkeitsmanagements. Die Prognose benötigt zusätzliche Informationen aus sonstigen Aktivitäten innerhalb des Sicherheits- und Zuverlässigkeitsprozesses und liefert wiederum wichtige Produktinformationen und Produkterfahrungen für alle Phasen des Produktentstehungsprozesses.

Die für die Analyse zur Verfügung stehenden Garantiedaten stammen im Allgemeinen aus einer 1 bis 3 jährigen Garantizeit. Mit Hilfe des Prognosemodells lässt sich das Ausfallverhalten und die Ausfallhäufigkeit auf eine Dauer von 5 bis 10 Jahre prognostizieren. Um das Langzeitverhalten von Komponenten und Baugruppen vorhersagen zu können, ist es notwendig, zusätzliche Untersuchungen vorzunehmen. Daher sollten die kritischen und verschleißträchtigen Teile zusätzlich mit Hilfe von Laborprüfungen und Lebensdauer tests untersucht werden. Auf diese Weise ist sicherzustellen, dass keine weiteren Ausfallmechanismen innerhalb der geplanten Nutzungsdauer, meist 10 bis 15 Jahre, auftreten.

Eine weitere unterstützende Maßnahme ist der Rückkauf von bereits im Feld befindlichen gleichen oder ähnlichen Baugruppen und Komponenten. Diese sollten auf mögliche Veränderungen und Anzeichen von Verschleiß untersucht werden. Ist kein Verschleiß festzustellen und zeigen die Ergebnisse der Lebensdauer versuche, dass ein Verschleiß innerhalb der geplanten Nutzungsdauer nicht zu erwarten ist, kann man davon ausgehen, dass mit Hilfe des Zuverlässigkeitsprognosemodells auch langfristige Vorhersagen über das zu erwartende Ausfallverhalten gemacht werden können.

### 4.2.2 Vorhandene Datenstruktur

Die für die Analyse zur Verfügung stehenden Daten stammen aus einer Garantiedatenbank, die im Wesentlichen für betriebswirtschaftliche Zwecke ausgelegt ist. Sie enthält jedoch auch viele Informationen, die für Zuverlässigkeitsbetrachtungen von Nutzen sind. Dieser vorhandene Fundus an Ausfallinformationen kann mit Hilfe des allgemeinen Zuverlässigkeitsprognosemodells aufbereitet und nutzbar gemacht werden. Die Garantiedatenbank enthält Informationen über die aufgetretenen Garantiefälle und einige Kulanzfälle, die jedoch für die weiteren Betrachtungen nicht genutzt werden können, da davon auszugehen ist, dass nicht alle nach der Garantizeit aufgetretenen Ausfälle auch vollständig in der Datenbank enthalten sind.

Die gespeicherten Garantiedaten werden meist nur für einen Teilmarkt erfasst, d.h. die Garantiedaten entsprechen nur einem Teil der real aufgetretenen Garantiefälle. Die ermittelte Anzahl von Garantiefällen muss daher, um auf die Grundgesamtheit schließen

zu können, mit einem Teilmarktfaktor korrigiert oder die betrachtete Grundgesamtheit (Verkaufsmenge) entsprechend um diesen Faktor reduziert werden. Die für die Zuverlässigkeitsprognose verwendeten Garantiedaten enthalten das Fertigungsdatum, das Zulassungsdatum, das Ausfalldatum und ein Registrier- bzw. Anerkennungsdatum, an dem der Garantiefall anerkannt und in die Datenbank aufgenommen wurde. Zusätzlich wird auch die gefahrene Strecke und ein Fehlercode für die Analyse ausgewertet. Mit Hilfe des Fehlercodes lassen sich die Ausfallteile und die Ausfallursachen jedes Garantiefalles ermitteln. Diese Information ist vor allem für das Sortieren und Separieren der Grundgesamtheit von Bedeutung. Tabelle 4.5 zeigt einen Ausschnitt eines Garantiedatensatzes. Das Fertigungs-, Zulassungs- und Ausfalldatum ist jeweils für den Monat eines Jahres angegeben. Die gefahrene Strecke bis zum Garantiefall wird hier mit TKM bezeichnet und ist auf tausend Kilometer gerundet. FNR bezeichnet die zugehörige Fehlernummer und TTNR die entsprechende Typeteilnummer des betrachteten Produktes.

**Tabelle 4.5: Auszug der Garantiedaten**

FertDat	ZulDat	AusfDat	AnerkDat	TKM	FNR	TTNR
199910	199912	200002	20000312	7	F000068123	130123456
199911	200001	200002	20000328	3	F221068100	130123456
199911	200002	200003	20000328	1	6000041123	130123456
200001	200002	200004	20000328	5	F300068123	130123456

Zusätzlich zu den Garantiedaten müssen die Fertigungs- und Verkaufsmengen für den Betrachtungszeitraum ermittelt werden. Diese bilden unter Berücksichtigung des zugehörigen Teilmarktfaktors die Grundgesamtheit der Betrachtung.

### 4.2.3 Bestimmung der Fahrleistungsverteilung

Um das Ausfallverhalten von Komponenten und Baugruppen im Kraftfahrzeug analysieren zu können, ist es notwendig, vorab die für den Fehlermechanismus relevanten Belastungsgrößen zu identifizieren. Die reine Einsatzdauer, d.h. die Zeitspanne zwischen Zulassungs- und Ausfallmonat, sagt im Allgemeinen nur wenig über die tatsächliche Belastung und Beanspruchung des zu untersuchenden Systems aus und sollte nach Möglichkeit nicht verwendet werden. Untersucht man jedoch benutzungsunabhängige Ausfälle, wie zum Beispiel Alterungsprozesse des Materials oder ähnliches, kann auch die Einsatzdauer als Belastungsgröße von Interesse sein. Für das Ausfallverhalten von Kfz-Komponenten ist die gefahrene Strecke oft eine wesentlich bessere Bezugsgröße, da sie meist direkt oder indirekt ein Maß für die tatsächlichen Betätigungen und die Betriebsdauer von Systemen im Kraftfahrzeug darstellt. Es hat sich gezeigt, dass es nicht



ausreichend ist, die Fahrleistung als Durchschnittswert anzugeben. Es ist vielmehr notwendig, eine Verteilungsfunktion der Fahrleistung zu ermitteln, die für verschieden Fahrzeugtypen stark variieren kann. Die Fahrleistungsverteilung eines bestimmten Fahrzeugtyps lässt sich durch gesonderte Untersuchungen oder direkt aus den Garantiedaten schätzen. Hat man eine ausreichend große Anzahl von Garantiefälle, die auf verschiedene Ausfallmechanismen zurückzuführen sind, stellen die Garantiedaten eine repräsentative Stichprobe für den entsprechenden Fahrzeugtyp dar, und es lässt sich daraus die zugehörige Fahrleistungsverteilung bestimmen [Pau00]. Geht man von einer monatlich konstanten Fahrleistung aus, ergibt sich die zu erwartende Gesamtfahrleistung jedes Fahrzeugs aus:

$$S_G = S_B \frac{t_G}{t_B}, \quad (4.6)$$

mit


$S_G$ : Zufallsvariable der Fahrleistung für die Garantiedauer,

$S_B$ : Zufallsvariable der Fahrleistung für die Betriebsdauer,

$t_G$ : Garantiedauer,

$t_B$ : Betriebsdauer.

Die Verteilungsfunktion  $L_G$  der Zufallsvariablen  $S_G$  ist die Fahrleistungsverteilung bezogen auf die Garantiezeit. Sie wird im Folgenden der Einfachheit halber nur noch mit Fahrleistungsverteilung bezeichnet. In vielen praktischen Untersuchungen hat sich gezeigt, dass sich zur Beschreibung der Fahrleistung besonders die logarithmische Normalverteilung eignet. Bild 4.3 zeigt beispielhaft den Verlauf der empirischen und theoretischen Laufleistungsverteilung eines Fahrzeugtyps. Die Parameter der Verteilungsfunktion wurden mit Hilfe der Maximum-Likelihood-Methode geschätzt.



**Bild 4.3: Empirische und theoretische Fahrleistungsverteilung**

Aus der Graphik lässt sich ablesen, dass etwa 50% der Fahrzeuge weniger als 25 Tkm innerhalb der Garantiezeit zurücklegen. 90% fahren höchstens 50 Tkm. Das bedeutet, dass 40% aller Fahrzeuge dieses Fahrzeugtyps zwischen 25 Tkm und 50 Tkm, bezogen auf die Garantiezeit fahren.

Im Laufe der Untersuchungen hat sich gezeigt, dass es erhebliche Unterschiede zwischen den einzelnen Fahrzeugtypen gibt und es daher unerlässlich ist, die spezifische Fahrleistungsverteilung zu bestimmen. Die Garantiedaten sollten für die Ermittlung der Fahrleistungsverteilung jedoch nur verwendet werden, wenn eine ausreichende Anzahl von zufällig wirkenden Ausfallmechanismen vorhanden ist. Ist dies nicht der Fall, können auch weitere Garantiedaten von sonstigen Systemen aus dem betrachteten Fahrzeugtyp für die Untersuchung verwendet werden.

#### 4.2.4 Entwicklung des Ausfallmodells

Die Entwicklung eines zur Beschreibung des Ausfallverhaltens geeigneten Ausfallmodells ist ein besonders wichtiger Schritt der Zuverlässigkeitsprognose. Das Ausfallmodell sollte, in Abhängigkeit von der Fragestellung, so einfach wie möglich und nur so genau wie nötig gewählt werden. Ein zu detailliertes Ausfallmodell enthält meist zu viele unbekannte Parameter und kann daher leicht zu einem „over-fitting“ führen, d.h. das Modell beschreibt nur noch die zufällige Stichprobe und nicht mehr die zu Grunde liegende Verteilungsfunktion. Es ist daher wichtig, bei der Zuverlässigkeitsprognose nicht nur allein die Garantiedaten zu analysieren, sondern des Weiteren zusätzliche Informationen über die Fehlerursachen und -wirkungen zu sammeln und auszuwerten.

Nicht vernachlässigbar sind hierbei die subjektiven Expertenmeinungen und das im Unternehmen vorhandene Erfahrungswissen.

Um einen ersten Eindruck und einen Überblick von dem Ausfallverhalten einer Komponente oder Baugruppe zu bekommen, eignen sich besonders parameterfreie und graphische Verfahren. Mit Hilfe dieser Methoden lässt sich der qualitative Verlauf der Zuverlässigkeitskenngrößen ermitteln. Besonders hilfreich sind hierbei die empirische Ausfallrate und Ausfalldichte. Weist beispielsweise die ermittelte empirische Ausfalldichte mehrere Maxima (Peaks) auf, deutet dies auf mehrere Ausfallmechanismen bzw. eine Inhomogenität der Grundgesamtheit hin. Eine erste Abschätzung der Zuverlässigkeit eines Systems bei zensierten Daten lässt sich mit dem Kaplan-Meier-Schätzverfahren durchführen. Erläuterung zu diesem Verfahren findet man u.a. in [Kap58, Mee98]. Der Verteilungstyp einer Grundgesamtheit lässt sich mit Hilfe von Lebensdauernetzen abschätzen und überprüfen. Lebensdauernetze existieren u.a. für Weibull-, normal- und logarithmisch normalverteilte Grundgesamtheiten. Die Anwendung und Auswertung von Lebensdauernetzen wird in [Mey03] ausführlich beschrieben und soll hier nicht weiter betrachtet werden. Zusätzliche Informationen zur Wahl eines geeigneten Ausfallmodells liefert eine Analyse der Fertigungsprozesse sowie die Ermittlung und Bewertung von Qualitätsschwankungen bei Zulieferteilen. Kann beispielsweise eine Ausfallmenge einem bestimmten begrenzten Fertigungszeitraum zugeordnet werden, deutet dies auf ein Chargenproblem hin. In Bezug auf die gesamte Fertigungsmenge ist dann nur diese Teilpopulation von dem speziellen Fehler betroffen. Ein solches Ausfallverhalten lässt sich mit einem Teilpopulations-Ausfallmodell beschreiben. Die folgenden Tabellen zeigen verschiedene, für die Lebensphasen eines Produktes typischen, Fehlerursachen.

**Tabelle 4.6: Fehlerursachen für Frühausfälle nach [Kec91]**

1.	Mangelhafte Fertigungsmethoden, Fertigungsprozesse, Handhabung und Montage,
2.	Mangelhafte Qualitätskontrolle und -sicherung,
3.	Mangelhaft ausgebildete Mitarbeiter,
4.	Unzureichende „burning in“-Dauer,
5.	Unzureichende „breaking in“-Dauer,
6.	Unzureichende Fehlersuche und -behebung,
7.	Minderwertige Materialien,
8.	Minderwertige Bauteile,

9. Ersetzung defekter Teile durch ungeprüfte Teile,
10. Fehlerhafte Lagerung und Transport,
11. Überspannungen bei Inbetriebnahme,
12. Kontaminierung, Verschmutzung,
13. Menschliche Fehler,
14. Unzulässige Installation,
15. Missbräuchlicher Einsatz.

**Tabelle 4.7: Fehlerursachen für zufällige Fehler nach [Kec91]**

1. Überschneiden der Auslegung eines Systems mit den tatsächlichen Belastungen während des Einsatzes,
2. Unzureichende Sicherheitsfaktoren in der Designauslegung,
3. Auftreten höherer als erwarteter zufälliger Belastungen,
4. Auftreten niedrigerer als erwarteter zufälliger Belastungen,
5. Defekte, die nicht erkannt werden können,
6. Menschliche Fehler beim Gebrauch,
7. Falsche Verwendung,
8. Missbrauch,
9. Nicht behebbare Fehler, die auch durch Wartung nicht ausgeschlossen werden können,
10. Nicht erklärbare Fehler,
11. Höhere Gewalt, wie Erdbeben, Blitzschlag, Sturm, Überschwemmungen usw.

**Tabelle 4.8: Fehlerursachen für Spätausfälle nach [Kec91]**

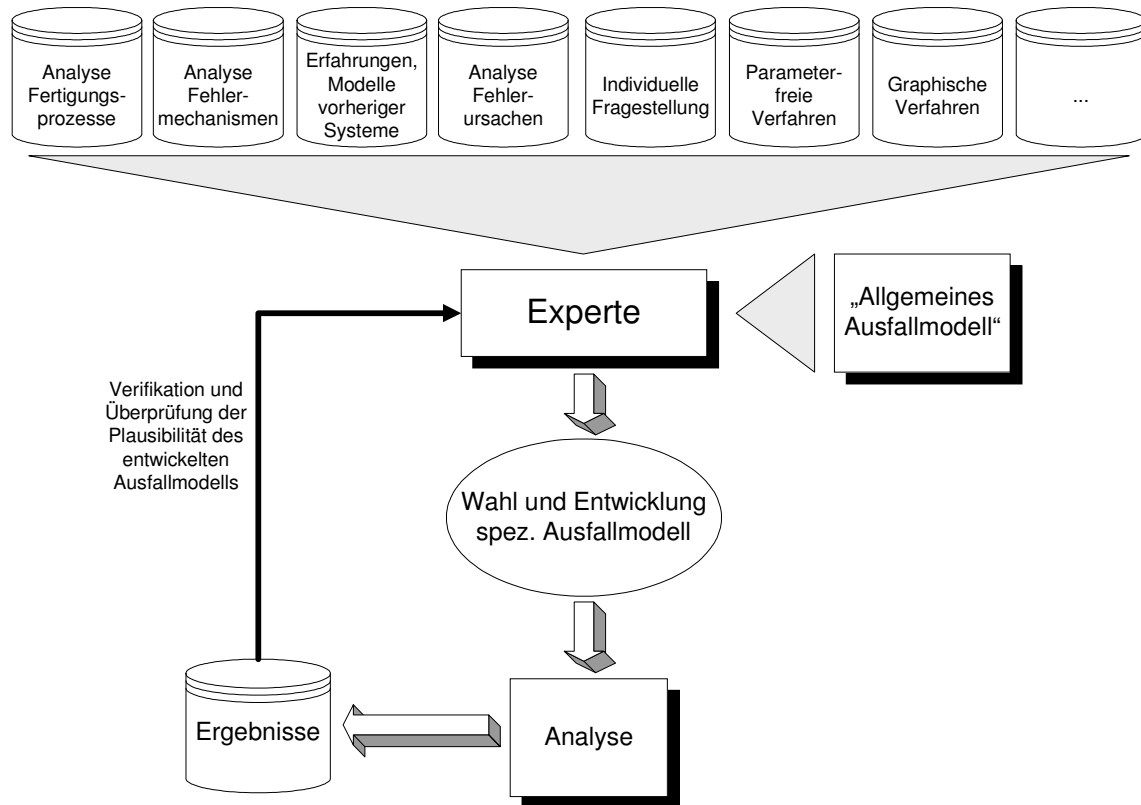
1. Alterung,
2. Verschleiß,
3. Minderung der Festigkeit,
4. Ermüdung,

5. Kriechen und Dehnung,
6. Korrosion,
7. Mechanische, elektrische, chemische oder hydraulische Verschlechterung bzw. Entartung,
8. Mangelhafte Wartung, Instandhaltung und Reparatur,
9. Fehlerhafte Auslegung der Lebensdauer.

Mit Hilfe der in den Tabellen aufgelisteten Fehlerursachen, können mögliche Schwachstellen systematisch identifiziert und gezielt Maßnahmen zur Fehlerreduktion ergriffen werden. Die Frühausfallphase kann je nach Betrachtungseinheit und Reifezustand des Herstellungsprozesses nicht vorhanden sein oder sich über einige tausend Betriebsstunden erstrecken. Die Zahl der Frühausfälle lässt sich durch gezielte Präventivmaßnahmen in der Entwicklungs- und Fertigungsphase senken [Bir91]. Spätausfälle können dagegen nur verringert werden, indem die von Verschleiß betroffenen Bauteile rechtzeitig ausgewechselt, bzw. nach Möglichkeit Materialien und Konzeptionen eingesetzt werden, deren Alterungsprozess langsamer verläuft.

Das folgende Bild 4.4 zeigt den Entscheidungsprozess für die Wahl und Entwicklung eines geeigneten Ausfallmodells.

Die Aufgabe eines Experten oder eines Expertenteams ist, ein für die Zuverlässigkeitsprognose einer Kfz-Komponente geeignetes Ausfallmodell zu entwickeln. Hierzu müssen vorab alle zur Verfügung stehenden Informationen zu den Fehlermechanismen und Fehlerursachen gesammelt und analysiert werden. Unterstützend können auch die Analyseergebnisse von ähnlichen Systemen genutzt werden. Nach ersten parameterfreien und graphischen Auswertungen der Ausfalldaten ist unter Berücksichtigung der individuellen Fragestellung aus dem allgemeinen Ausfallmodell ein spezielles Ausfallmodell zu entwickeln. Auf Basis dieses individuellen Modells wird dann die Analyse der Felddaten durchgeführt. Es ist bei der Modellentwicklung unerlässlich, die gewonnenen Ergebnisse zu verifizieren und deren Plausibilität zu überprüfen.



**Bild 4.4: Prozess zur Wahl des Ausfallmodells**

Wurde ein geeignetes Ausfallmodell entsprechend der in Bild 4.4 dargestellten Vorgehensweise entwickelt, können in den nächsten Schritten der Zuverlässigkeitsprognose die km- und zeitabhängigen Zuverlässigkeitskenngrößen für Kfz-Komponenten und Baugruppen bestimmt werden.

#### 4.2.5 Bestimmung der km-abhängigen Zuverlässigkeitskenngrößen

Die für die Analyse verwendeten Garantiedaten sind zeitlich auf die Garantiedauer beschränkt. Alle nicht ausgefallenen Fahrzeuge werden innerhalb der Garantiezeit entsprechend der zugehörigen Fahrleistungsverteilung eine bestimmte Strecke zurücklegen. Sie liefern damit die Information, welche Fahrstrecke sie mindestens ohne Ausfall überdauert haben. Man spricht in einem solchen Fall auch von einer Rechts-Zensierung.

Um nun diese zusätzlichen Informationen nutzen zu können, müssen geeignete Ansätze entwickelt werden. Eine Möglichkeit, die Zensierungen zu berücksichtigen und damit die km-abhängigen Zuverlässigkeitskenngrößen zu bestimmen, ist die Maximum-Likelihood-Methode. Anhand von Auswertungen konnte jedoch gezeigt werden, dass diese sich nur bedingt für die Auswertung eignet, da sie in den meisten Fällen die An-

zahl der Überlebenden zu stark gewichtet und damit nur eine ungenaue Beschreibung des km-abhängigen Ausfallverhaltens der zu untersuchenden Komponente liefert.

Alternative Methoden sind die Verfahren von Eckel [Eck77], das vom VDA vorgeschlagene Medianrang-Verfahren [VDA84] oder das Verfahren von Pauli [Pau99]. Alle diese Verfahren gleichen die Zensierung bis zum höchsten bekannten km-Stand, bei dem sich ein Ausfall ereignet hat, aus. Die Stichproben sind dann bis zu diesem km-Stand als vollständig anzusehen und können entsprechend ausgewertet werden. Die Verfahren stellen jedoch nur eine Näherung dar und vernachlässigen die zusätzlich vorhandenen Informationen, die über den höchsten km-Stand hinaus vorliegen.


Für diese Arbeit wird, auf Grund der leichten praktischen Anwendbarkeit, das Verfahren von Pauli zur Bestimmung der km-abhängigen Kenngrößen verwendet. Untersuchungen haben gezeigt, dass es nur minimale Abweichungen zu den anderen genannten Verfahren gibt.

Bei dem gewählten Ansatz werden die bei einer Fahrstrecke  $s$  aufgetretenen Ausfallzahlen korrigiert. Alle vor diesem bestimmten km-Stand rechtszensierten Fahrzeuge haben innerhalb der Garantiezeit diese Strecke noch nicht zurückgelegt. Von diesen Fahrzeugen wird ein gewisser Teil jedoch noch bis zu dem entsprechenden km-Stand zusätzlich ausfallen. Man nennt diese Fahrzeuge auch Anwärter. Die Zahl der insgesamt zu erwartenden Ausfälle lässt sich leicht über die bereits bekannten Ausfälle  $n_G(s)$  und die zuvor bestimmte Fahrleistungsverteilung  $L_G(s)$  schätzen, wobei die Aussagegenauigkeit mit höheren Fahrleistungen entsprechend abnimmt.

Für die korrigierte Gesamtzahl  $n_k(s)$  von Ausfällen bei einer Fahrstrecke  $s$  gilt dann:

$$n_k(s) = \frac{n_G(s)}{1 - L_G(s)}. \quad (4.7)$$


In Bild 4.5 ist die empirische km-abhängige Ausfallwahrscheinlichkeit für die erfassten und die korrigierten Ausfälle aufgetragen. Man kann leicht erkennen, dass mit zunehmender Fahrstrecke der Korrekturfaktor entsprechend zunimmt.



**Bild 4.5: Empirische Ausfallwahrscheinlichkeiten für erfasste und korrigierte Ausfälle**

Die korrigierte empirische Ausfallwahrscheinlichkeit gibt die unzensierten Ausfallzahlen wieder und kann entsprechend statistisch ausgewertet werden. Zur Anpassung einer stetigen Verteilungsfunktion hat sich die Methode der kleinsten Quadrate als besonders geeignet erwiesen. Die Methode liefert, unter der Zuhilfenahme numerischer Optimierungsverfahren, Schätzungen für die unbekannt Parameter einer anzupassenden Verteilungsfunktion. Als numerische Optimierungsverfahren werden das Newton-Raphson-Verfahren und die Sekanten-Methode verwendet.

Zur Beschreibung des km-abhängigen Ausfallverhaltens von Kfz-Komponenten und Baugruppen hat sich als Verteilungsmodell besonders die Weibull-Verteilung bewährt. Bild 4.6 zeigt die angepasste und die empirische km-abhängige Ausfallwahrscheinlichkeit einer Kfz-Komponente.



**Bild 4.6: Empirische und angepasste theoretische Ausfallwahrscheinlichkeit (Weibull-Verteilung)**



Mit Hilfe der ermittelten km-abhängigen Ausfallwahrscheinlichkeit lassen sich auch alle weiteren km-abhängigen Zuverlässigkeitskenngrößen bestimmen.

In der praktischen Anwendung ist die gefahrene Strecke als Maßeinheit für die Lebensdauer einer Komponente oder Baugruppe eher unüblich. Man möchte daher im letzten Schritt des Prognosemodells wieder eine Zeitabhängigkeit der Lebensdauer herstellen. Dies hat den Vorteil, dass Aussagen ohne zeitliche Einschränkungen und damit über die Garantiezeit hinaus möglich werden.

#### 4.2.6 Bestimmung der zeitabhängigen Zuverlässigkeitskenngrößen

Für die Bestimmung der zeitabhängigen Zuverlässigkeitskenngrößen ist es notwendig, die Fahrleistungsverteilung umzuformen. Man möchte nun wissen, wie lange die Kraftfahrzeuge eines Kunden höchstens benötigen, bis sie eine bestimmte Strecke  $s$  zurückgelegt haben. Bezeichnet man die benötigte Zeitdauer mit der Zufallsvariable  $Z_s$  und die zugehörige Verteilungsfunktion mit  $A_s$ , dann gilt:

$$A_s(t) = P(Z_s \leq t) = 1 - L_t(s) = 1 - L_G\left(\frac{g \cdot s}{t}\right). \quad (4.8)$$

Eine ausführliche Herleitung wird in [Pau98] gegeben.

Gesucht wird nun die zeitabhängige Ausfallwahrscheinlichkeit  $F(t)$ , die keiner zeitlichen Beschränkung unterliegt. Geht man davon aus, dass  $F(t)$  als Zusammenwirken zweier unabhängiger Ereignisse aufgefasst werden kann, lässt sich daraus folgende Formel herleiten:

$$F(t) = P(T \leq t) = \int_0^{\infty} f_k(\zeta) \cdot A_{\zeta}(t) d\zeta, \quad (4.9)$$

mit  $f_k$ : km-abhängige Dichtefunktion, uneingeschränkt.


Die Berechnung dieser Gleichung ist meist nur numerisch möglich.

Die zeitabhängige Ausfallrate berechnet sich entsprechend aus:


$$h(t) = \frac{\int_0^{\infty} f_k(\zeta) \cdot a_{\zeta}(t) d\zeta}{1 - \int_0^{\infty} f_k(\zeta) \cdot A_{\zeta}(t) d\zeta}, \quad (4.10)$$

mit  $a_{\zeta}(t)$ : Dichtefunktion von  $A_{\zeta}(t)$ .

In Bild 4.7 und Bild 4.8 sind die aus der km-abhängigen Ausfalldichte und der zugehörigen Fahrleistungsverteilung ermittelte zeitabhängige Ausfallwahrscheinlichkeit und Ausfallrate aufgetragen.



**Bild 4.7: Zeitabhängige Ausfallwahrscheinlichkeit**



**Bild 4.8: Zeitabhängige Ausfallrate**

Im folgenden Abschnitt werden die Ergebnisse der durchgeführten Untersuchungen und die dafür entwickelten Ausfallmodelle dargestellt und diskutiert.

## 4.3 Ergebnisse

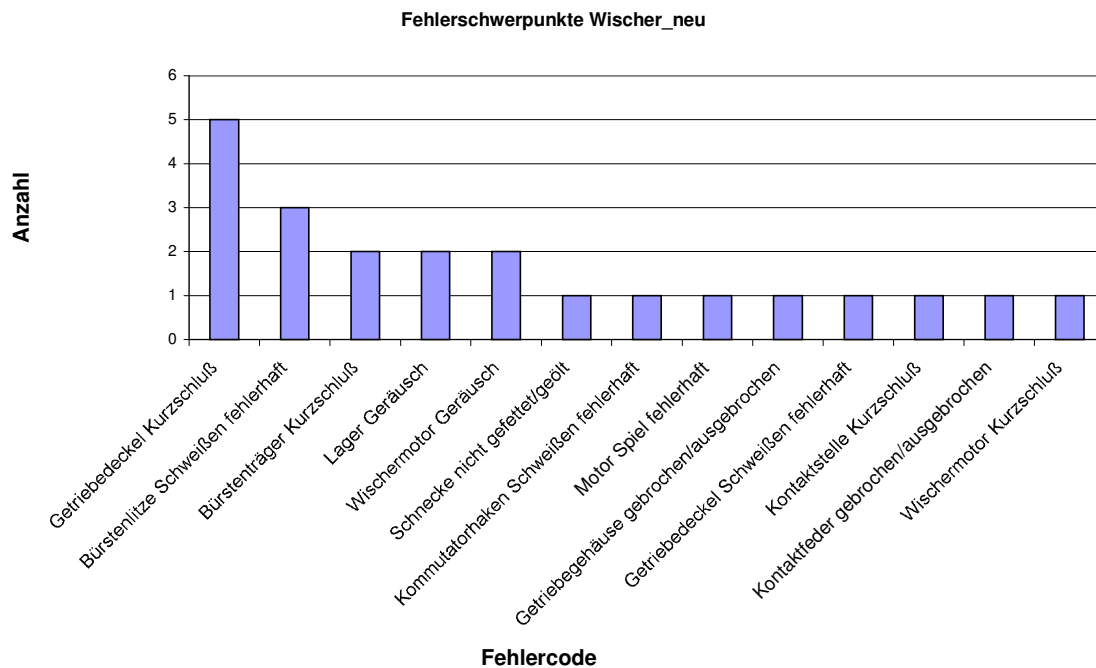
### 4.3.1 Wischermotoren

Im Rahmen dieser Analyse werden verschiedene Wischermotoren hinsichtlich ihres Feldausfallverhaltens untersucht. Ziel ist es, den neu entwickelten Wischermotor „Wischer\_neu“ mit den bisher im gleichen Trägerfahrzeug eingebauten Systemen zu vergleichen. Zur besseren Vergleichbarkeit wird versucht für alle untersuchten Motoren das gleiche Ausfallmodell zu verwenden. Auf Grundlage erster parameterfreier Auswertungen und Bewertung der korrigierten empirischen Zuverlässigkeitskenngrößen kann für alle zu untersuchenden Elektromotoren ein unimodales Ausfallmodell verwendet werden. Als Verteilungsmodell der km-abhängigen Kenngrößen wird eine Weibull-Verteilung angenommen. Die Anpassung der theoretischen Verteilungsfunktionen an die empirischen Daten wird zusätzlich mit Hilfe von P-P-Plots (Probability-Probability-Plots) bewertet.

#### **Wischer\_neu**

Zur Zeit der Analyse liegen für das zu untersuchende System nur eine geringe Zahl von Feldausfällen vor. Um erste Anhaltswerte für die Zuverlässigkeit zu erhalten, sollen im Folgenden dennoch erste statistische Betrachtungen für das System durchgeführt werden. Die Aussagekraft der gewonnenen Ergebnisse ist jedoch immer in Bezug auf die vorliegende Datenmenge zu bewerten. In Bild 4.9 sind die häufigsten Fehlerursachen für den untersuchten Wischer dargestellt.

Die Fehlerschwerpunkte des Wischer\_neu weisen auf ein typisches Frühausfallverhalten hin, das meist auf fertigungsbedingte Fehler zurückzuführen ist. Unter Zugrundelegung eines unimodalen Ausfallmodells wird im Folgenden eine Zuverlässigkeitsprognose nach der entwickelten Vorgehensweise durchgeführt.



**Bild 4.9: Fehlerschwerpunkte Wischer\_neu**

Zur Bewertung des Ausfallverhaltens von Kfz-Komponenten eignet sich besonders die Ausfallrate, da sie auch rein qualitative interpretierbar ist und die charakteristische Wirkungsweise der Fehlermechanismen zeigt. Die zeitabhängige Ausfallrate des Wischer\_neu zeigt ein typisches Frühausfallverhalten (Bild 4.10). Ein solches Ausfallverhalten ist meist auf fertigungsbedingte Fehler zurückzuführen. Die Ausfallrate beträgt nach sechs Monaten 199,6 ppm/Jahr und fällt innerhalb des ersten Jahres auf nur noch 107,2 ppm/Jahr. Das heißt, innerhalb der ersten elf Monate fällt die Ausfallrate um 46,29 %. Nach zwei Jahren liegt die Ausfallrate bei 78,57 ppm/Jahr und verläuft danach nahezu konstant. Der Verlauf der zeitabhängigen Ausfallrate ist in Bild 4.10 dargestellt. In Tabelle 4.9 sind die Ergebnisse der durchgeführten Parameterschätzungen zusammengefasst.




Bild 4.10: Zeitabhängige Ausfallrate des Wischer\_neu

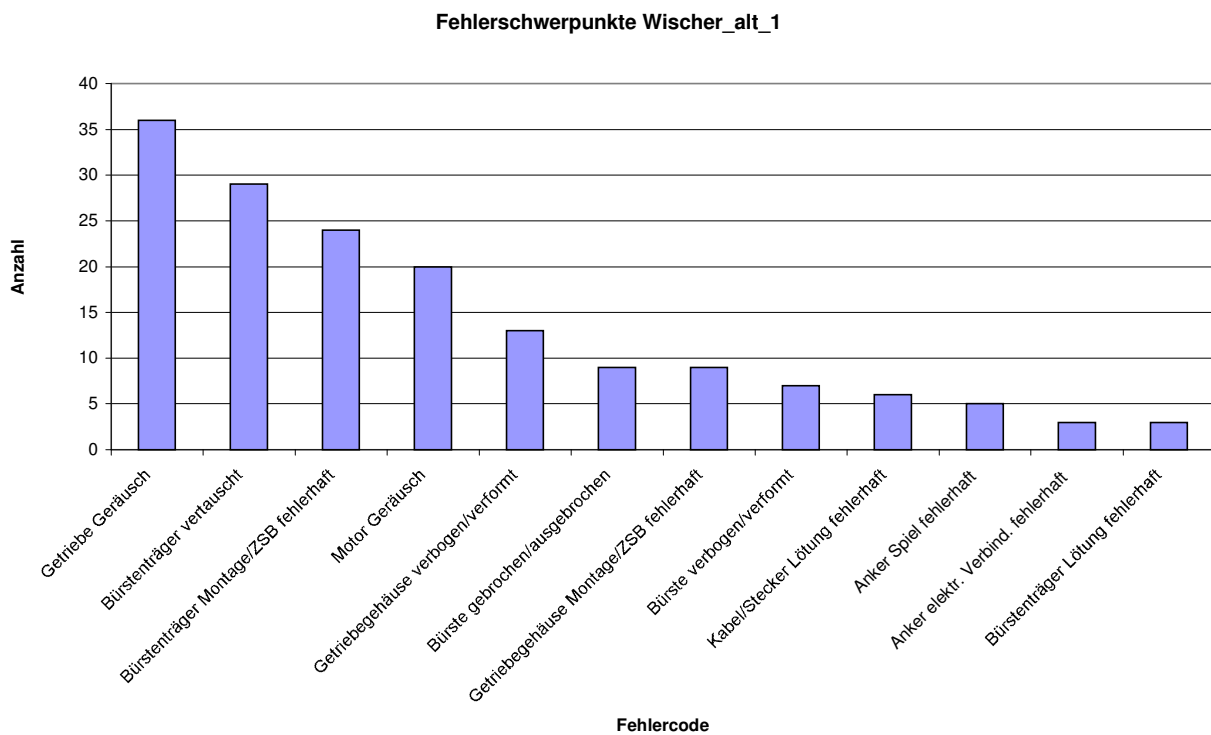
Tabelle 4.9: Geschätzte Parameter der Verteilungsfunktionen Wischer\_neu

	$\mu$	$\sigma$
Fahrleistungsverteilung (Lognormal-Verteilung)	3,18947	0,642532
	$\alpha$	$\beta$
Km-abhängige Kenngrößen (Weibull-Verteilung)	3,11315 E-05	0,554246
zeitabhängige Kenngrößen (Weibull-Verteilung)	1,94294 E-04	0,551745

### Wischer\_alt\_1

Bei diesem Wischermotor handelt es sich um ein Vorgängermodell des Wischer\_neu, der im gleichen Fahrzeugtyp bzw. in den Vorgängerfahrzeugen eingebaut wurde. Es soll nun exemplarisch eine Bewertung der Ergebnisse für den Wischermotor Wischer\_alt\_1 erfolgen.

Auf Grundlage erster parameterfreier und graphischer Untersuchungen und des vorhandenen Wissens über die wirkenden Fehlermechanismen kann bei der Zuverlässigkeitsprognose dieses Wischermotors ebenfalls ein unimodales Ausfallmodell zu Grunde gelegt werden. In Bild 4.11 sind die häufigsten Fehlerursachen des Wischermotors dargestellt.



**Bild 4.11: Fehlerschwerpunkte Wischer\_alt\_1**

Anhand der Fehlercodes der Garantiedaten lässt sich erkennen, dass es sich bei den Ausfällen vorwiegend um fertigungsbedingte Fehler handelt. Diese Vermutung wird auch durch den Verlauf der prognostizierten zeitabhängigen Ausfallrate verstärkt, die ein typisches Frühausfallverhalten zeigt (Bild 4.12).




Bild 4.12: Zeitabhängige Ausfallrate Wischer\_alt\_1

Die Ausfallrate fällt bei diesem Wischermotor innerhalb des ersten Jahres von 201,5 ppm/Jahr auf 51,8 ppm/Jahr. Im zweiten Jahr beträgt sie nur noch 35,46 ppm/Jahr und kann im weitem Verlauf als nahezu konstant angesehen werden. Das heißt, die Ausfälle treten dann nur noch rein zufällig auf. Die geschätzten Parameter der Zuverlässigkeitsprognose sind in Tabelle 4.10 aufgeführt.

Tabelle 4.10: Geschätzte Verteilungsparameter Wischer alt\_1

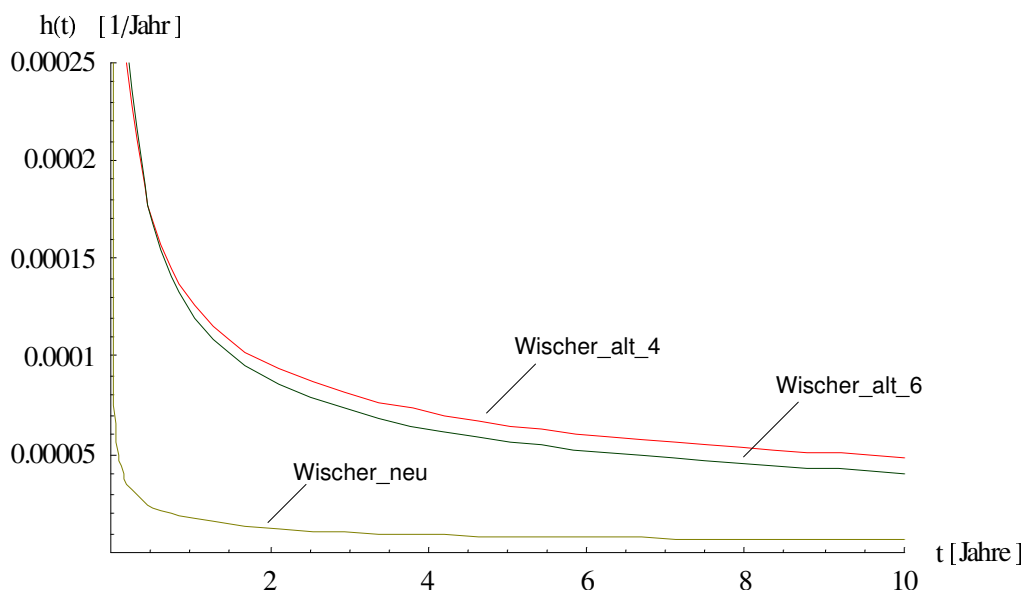
	$\mu$	$\sigma$
Fahrleistungsverteilung (Lognormal-Verteilung)	2,96451	0,715693
	$\alpha$	$\beta$
Km-abhängige Kenngrößen (Weibull-Verteilung)	2,81262 E-05	0,45499
zeitabhängige Kenngrößen (Weibull-Verteilung)	1,1427 E-04	0,45331

Das entwickelte Zuverlässigkeitsprognosemodell ist ein Werkzeug, um die in den Felddaten vorhandenen Informationen nutzbar zu machen. Untersucht man beispielsweise verschiedene Generationen von Produkten, die im gleichen Fahrzeug eingebaut wurden,

lassen sich relativ einfach Vergleiche anstellen. Mit Hilfe des allgemeinen Prognosemodells kann beispielsweise untersucht werden, wie sich Design- oder Applikationsänderungen auf die Zuverlässigkeit der Produkte ausgewirkt haben. Eine alternative Anwendung ist die Untersuchung vergleichbarer Systeme, die in verschiedenen Fahrzeugen oder in verschiedenen Zonen im Fahrzeug eingebaut wurden. Es kann des Weiteren auch das Ausfallverhalten von Produkten verglichen werden, die in verschiedenen Märkten verkauft wurden. Diese Anwendungen stellen nur eine Auswahl der vielseitig nutzbaren Prognoseergebnisse dar. Es soll nun beispielhaft ein Vergleich von Wischermotoren, die im gleichen Fahrzeug eingebaut wurden, vorgenommen werden.

Das Ausfallverhalten der untersuchten Wischermotoren ist qualitativ ähnlich. Die Ausfallrate zeigt bei allen ein typisches Frühausfallverhalten, das unter Berücksichtigung der ermittelten Ausfallschwerpunkte meist auf Fertigungsfehler zurückgeführt werden kann.

Bild 4.13 zeigt eine Gegenüberstellung der ermittelten zeitabhängigen Ausfallraten für die Wischergenerationen eines Fahrzeugs.

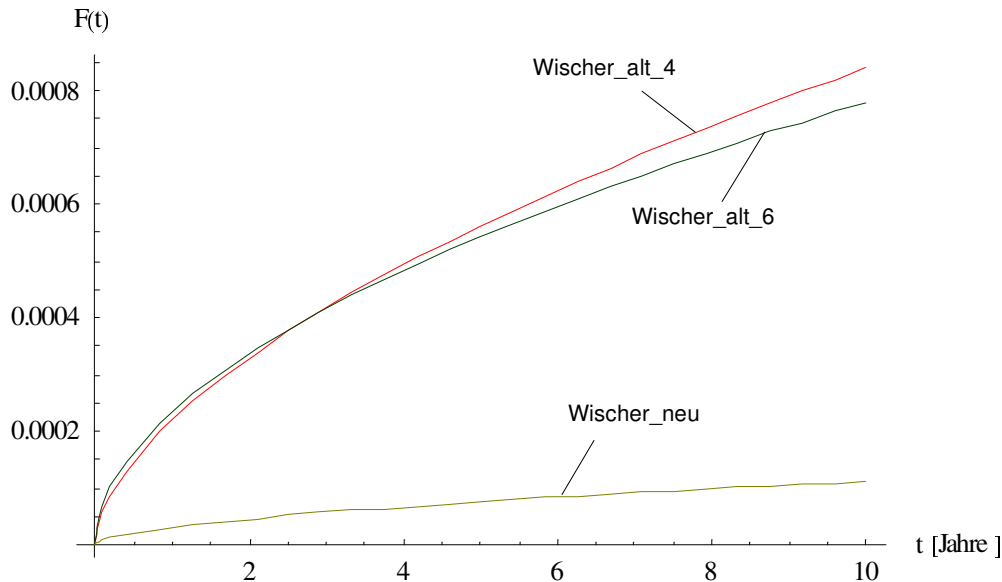


**Bild 4.13: Vergleich zeitabhängiger Ausfallraten**

In Bild 4.13 ist zu erkennen, dass die Ausfallraten von Wischer\_alt\_4 und Wischer\_alt\_6 nahezu identisch sind. Der Vergleich der unterschiedlichen Generationen von Wischermotoren zeigt, dass die zeitabhängige Ausfallrate von Wischer\_neu die günstigste in diesem Vergleich ist. Sie fällt innerhalb kurzer Zeit stark ab und ist schon nach einem halben Jahr nahezu konstant. Zum weiteren Vergleich der verschiedenen



Wischsysteme sind in Bild 4.14 zusätzlich die zugehörigen zeitabhängigen Ausfallwahrscheinlichkeiten dargestellt.



**Bild 4.14: Vergleich zeitabhängiger Ausfallwahrscheinlichkeiten**

Auch in dieser Darstellung lässt sich erkennen, dass der Wischermotor Wischer\_neu hinsichtlich der Zuverlässigkeit das beste Konzept ist. Die beiden anderen Wischermotoren besitzen eine etwa um den Faktor acht höhere Ausfallwahrscheinlichkeit bezogen auf die Zeit im Felde. Mit Hilfe der Prognoseergebnisse lassen sich, wie in dem Beispiel gezeigt, frühere Design-Entscheidungen verifizieren und deren Erfolg quantitativ bewerten.

Diese und ähnliche Anwendungen zeigen die Möglichkeiten des allgemeinen Zuverlässigkeitsprognosemodells, wertvolle Informationen für die Produktentwicklung zu liefern, vorhandenes Informationen nutzbar zu machen und wertschöpfend in die betrieblichen Abläufe zu integrieren. Die Prognoseergebnisse weitere untersuchter Wischsysteme befinden sich im Anhang.

### 4.3.2 Kupplungsteller

Der untersuchte Kupplungsteller ist ein Beispiel für ein komplexes Kfz-System. Bei der Analyse der Fehlermechanismen und Fehlerursachen wurde als Hauptfehlerursache der fehlerhafte Durchmesser der Bürstentasche bei dem integrierten elektrischen Antrieb identifiziert. Dieser Ausfall ist auf eine fehlerhafte Fertigung zurückzuführen. Um das Ausfallverhalten des Gesamtsystems beschreiben zu können, wird im Folgenden ein

geeignetes Ausfallmodell entwickelt. Dieses Modell wird anschließend mit einem unimodalen Ansatz verglichen.

### Ausfallmodell

Für die Analyse des Kupplungstellers ist es notwendig ein spezielles Ausfallmodell zu entwickeln. Die Felddaten werden hierzu nach ihren Fehlerursachen in zwei Subpopulationen separiert. Die erste Subpopulation enthält alle Ausfälle mit der Hauptfehlerursache „fehlerhafter Durchmesser der Bürstentasche“ (Fehlerursache 1). Alle sonstigen Fehler werden in der zweiten Subpopulation (Restpopulation) erfasst (Fehlerursache 2). Als übergeordnetes Modell wird ein konkurrierendes Ausfallmodell angenommen. Das bedeutet, dass zu jedem Zeitpunkt bzw. gefahrener Strecke sich ein Ausfall auf Grund der Fehlerursache 1 oder Fehlerursache 2 ereignen kann. Für die km-abhängige Ausfallwahrscheinlichkeit bedeutet dies:

$$F(s) = 1 - (1 - F_1(s))(1 - F_2(s)), \quad (4.11)$$

mit

$F_1(s)$ : Ausfallwahrscheinlichkeit für Fehlerursache 1,

$F_2(s)$ : Ausfallwahrscheinlichkeit für Fehlerursache 2.

Da die Ausfälle mit der Fehlerursache „fehlerhafter Durchmesser der Bürstentasche“ nur innerhalb einer Teilpopulation auftreten können, wird zur Beschreibung der Ausfallwahrscheinlichkeit  $F_1(s)$  ein Teilpopulations-Ausfallmodell verwendet. Es gilt dann:

$$\begin{aligned} F(s) &= 1 - \left( 1 - \left[ \frac{n_{11}}{n} F_{11}(s) + \frac{n_{12}}{n} F_{12}(s) \right] \right) (1 - F_2(s)) \\ &\approx \frac{n_{11}}{n} F_{11}(s) - \frac{n_{11}}{n} F_2(s) F_{11}(s) + F_2(s) \\ &= w_{11} F_{11}(s) - w_{11} F_2(s) F_{11}(s) + F_2(s) \end{aligned} \quad (4.12)$$

mit

$n_{11}$ : Anzahl der Produkte mit fertigungsbedingter Vorschädigung,

$n_{12}$ : Anzahl der Produkte ohne fertigungsbedingter Vorschädigung,

$F_{11}(s)$ : Ausfallwahrscheinlichkeit für Produkte mit fehlerhaftem Durchmesser,

$F_{12}(s)$ : Ausfallwahrscheinlichkeit für Produkte ohne Vorschädigung  
( $F_{12}(s) \approx 0$ ).


Bei der Verteilungsfunktion  $F_{11}(s)$  handelt es sich um eine bedingte Wahrscheinlichkeit. Sie gibt die Wahrscheinlichkeit wieder, mit der eine Komponente ausfällt, unter der Bedingung, dass sie eine fertigungsbedingte Vorschädigung („fehlerhafter Durchmesser“) besitzt. Für die Zuverlässigkeitsanalyse sind beide Fehlerursachen separat zu untersuchen und anschließend, entsprechend dem erstellten Ausfallmodell, zu kombinieren.

### Ausfallwahrscheinlichkeit Fehlerursache 1

Wie schon beschrieben, handelt es sich bei der Fehlerursache 1 um einen bedingten Fehler, der sich nur ereignen kann, wenn das Produkt eine fertigungsbedingte Vorschädigung besitzt. Der Anteil  $w_{11}$  dieser Produkte ist jedoch unbekannt und muss ebenfalls bei der Analyse bestimmt werden. Die Grundidee hierbei ist, dass  $F_1(s)$  für  $s \rightarrow \infty$  gegen den Grenzwert  $w_{11}$  strebt. Setzt man nun diese Beziehung in den Kleinst-Quadrat-Schätzer ein, erhält man:


$$SSE = \sum_i \left( F_{11}(s_i) - \frac{n_a(s_i)}{n_{11}} \right)^2. \quad (4.13)$$

Leitet man nun die Summe partiell nach der  $n_{11}$  ab und setzt diese Ableitung gleich Null, so lässt sich bei der Parameterschätzung mit der Methode der kleinsten Quadrate auch  $n_{11}$  näherungsweise bestimmen. Wobei  $n_{11}$  der Anzahl von Produkten mit einem fehlerhaften Durchmesser der Bürstentasche entspricht. Für die km-abhängige Ausfallwahrscheinlichkeit für die Fehlerursache 1 ergibt sich die in Bild 4.15 dargestellte Anpassung einer Weibull-Verteilung an die empirischen Daten.  $F_{11}(s)$  entspricht der Ausfallwahrscheinlichkeit der Systeme aus der betroffenen Teilpopulation.



**Bild 4.15: Km-abhängige Ausfallwahrscheinlichkeit Fehlerursache 1**

Die Güte der Anpassung zeigt der in Bild 4.16 dargestellte P-P-Plot.



**Bild 4.16: P-P-Plot Anpassung km-abhängige Ausfallwahrscheinlichkeit Fehlerursache 1**

### Ausfallwahrscheinlichkeit Fehlerursache 2

Diese Art von Fehler unterliegt keinerlei Einschränkung und kann bei der gesamten Verkaufsmenge der Produkte auftreten. Entsprechend gilt für die zu betrachtende Grundgesamtheit die gesamte Verkaufsmenge. Als theoretische Verteilungsfunktion wurde eine Weibull-Verteilung  $W(\alpha, \beta)$  an die empirische km-abhängige Ausfallwahrscheinlichkeit angepasst. Die folgenden Bilder zeigen die empirische und angepasste Ausfallwahrscheinlichkeit und die Güte der Anpassung in einem P-P-Plot ( Bild 4.17 und Bild 4.18).




Bild 4.17: Km-abhängige Ausfallwahrscheinlichkeit Fehlerursache 2


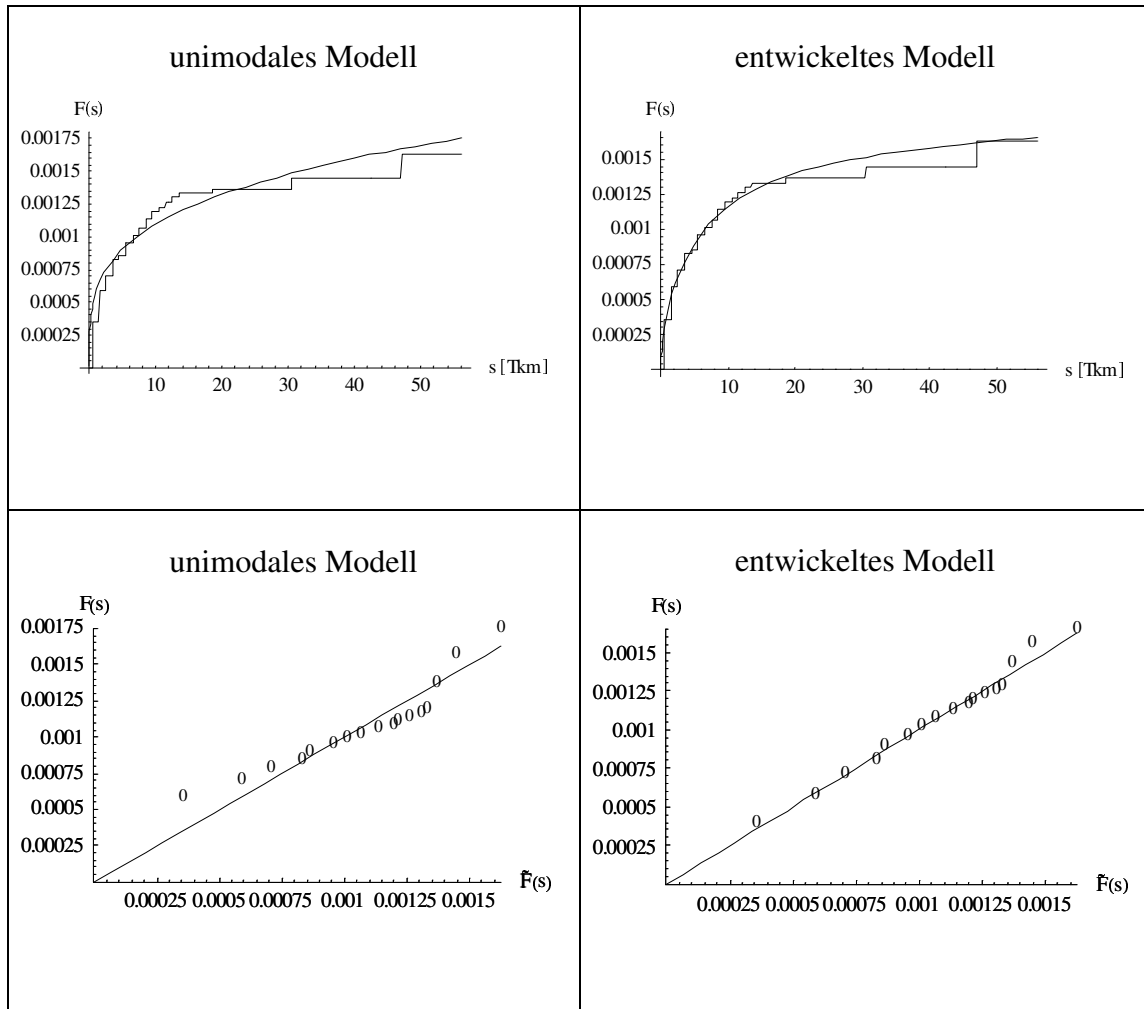


Bild 4.18: P-P- Plot Anpassung km-abhängige Ausfallwahrscheinlichkeit Fehlerursache 2


### Gesamtausfallwahrscheinlichkeit

Aus den ermittelten km-abhängigen Ausfallwahrscheinlichkeiten für die Fehlerursache 1 und Fehlerursache 2 lässt sich nach dem entwickelten Ausfallmodell die km-abhängige Gesamtausfallwahrscheinlichkeit des Systems bestimmen. Zum Vergleich wurde auch eine Zuverlässigkeitsprognose mit einem unimodalen Ausfallmodell durchgeführt. Die Ergebnisse beider Analysen sind in Bild 4.19 gegenübergestellt. Die dargestellten Kurvenverläufe zeigen, dass das entwickelte zusammengesetzte Ausfallmodell

sich wesentlich besser eignet, das tatsächliche Feldausfallverhaltens des Kupplungstellers zu beschreiben. Im letzten Schritt der Zuverlässigkeitsprognose werden die zeitabhängigen Zuverlässigkeitskenngrößen nach Gleichung (4.9) ermittelt. Diese können für das entwickelte Ausfallmodell nur numerisch bestimmt werden. Die ermittelte zeitabhängige Ausfallwahrscheinlichkeit ist in Bild 4.20 dargestellt.




**Bild 4.19: Vergleich unimodales und entwickeltes Ausfallmodell**



**Bild 4.20: Zeitabhängige Ausfallwahrscheinlichkeit des Kupplungstellers**

Die zugehörige zeitabhängige Ausfallrate des Kupplungstellers ist in Bild 4.21 abgebildet. Die Ausfallrate zeigt ein typisches Frühausfallverhalten. Nach einem Jahr ist die Ausfallrate nahezu konstant. Das heißt, zu diesem Zeitpunkt sind fast alle vorgeschädigten Teile ausgefallen, und alle weiteren Fehler treten nur noch rein zufällig auf.




**Bild 4.21: Zeitabhängige Ausfallrate des Kupplungstellers**

Die Analyse des Kupplungstellers zeigt, wie mit dem neuen allgemeinen Zuverlässigkeitsprognosemodell auch komplexe Kfz-Systeme analysiert und deren Feldausfallverhalten prognostiziert werden kann. So können nun die Analyseergebnisse von Subsystemen, auf Basis eines aus dem allgemeinen Ausfallmodell entwickelten individuellen Modells, für die Prognose des Gesamtsystems miteinander kombiniert werden.

### 4.3.3 Steuergeräte für Motorkühlgebläse

Als weitere Baugruppe von Kraftfahrzeugen werden verschiedene Steuergeräte von Motorkühlgebläsen untersucht. Eine Analyse der Fehlerursachen ist bei den ausgewählten Systemen nicht möglich, da für alle Ausfälle keine Fehlerursache im Fehlercode angegeben ist. Diese mangelhafte Datenqualität hat Auswirkungen auf die Zuverlässigkeitsprognose und macht diese nur unter Vorbehalt möglich. Der vorliegende Fall spiegelt einen in der Praxis häufig vorhandenen Sachverhalt wieder und wird daher für die folgenden Betrachtungen ausgewählt.

Auf Grund der empirischen Datenanalyse lässt sich vermuten, dass eine Anpassung mit Hilfe eines einfachen Ausfallmodells nur unzureichend ist und das wahre Feldverhalten nicht ausreichend gut wiedergibt. Bild 4.22 zeigt die empirische und nach dem einfachen Ausfallmodell angepasste Ausfallwahrscheinlichkeit für ein untersuchtes Steuergerät.



**Bild 4.22: Ausfallwahrscheinlichkeit für unimodales Ausfallmodell**

In Ergänzung zum Fehlercode konnten jedoch zusätzliche Informationen über die auftretenden Fehlermechanismen von Experten gewonnen werden. So scheinen sich die Ausfälle auf verschiedene Ausfallchargen zu konzentrieren. Dies lässt sich auf Schwankungen der Zulieferqualität und Fehler im Fertigungsprozess zurückführen. Auf Grundlage dieser zusätzlichen Informationen werden alternativ zwei weitere Ausfallmodelle aus dem allgemeinen Ausfallmodell entwickelt.

#### Ausfallmodell 1

Als erstes Ausfallmodell wird ein Teilpopulations-Ausfallmodell angenommen. Hierbei wird davon ausgegangen, dass die Ausfälle sich nur innerhalb einer nicht spezifizierten



Subpopulation ereignen. Die Ausfallwahrscheinlichkeit  $F(s)$  des untersuchten Steuergerätes kann bei diesem Ausfallmodell wie folgt beschrieben werden:

$$P(S \leq s) = F(s) = \frac{n_T}{n} F_T(s), \quad (4.14)$$


mit  $n_T$ : Anzahl vorgeschädigter Produkte,

$n$ : Grundgesamtheit aller Produkte,

$F_T(s)$ : Ausfallwahrscheinlichkeit der vorgeschädigten Produkte.

Für  $s \rightarrow \infty$  geht  $F(s) \rightarrow \frac{n_T}{n}$ .

Da bei den untersuchten Steuergeräten auf Grund der Datenqualität der Anteil vorgeschädigter Produkte nicht bekannt ist, muss dieser ebenfalls bei der Parameterschätzung bestimmt werden. Daher wird  $n_T$  als zusätzlicher Parameter in die Kleinste-Quadrate-Schätzung integriert und kann so mitgeschätzt werden (vgl. Analyse Kupplungsteller). Bei dem Modell geht man davon aus, dass sich außer den beschriebenen Ausfällen keinerlei sonstige Ausfälle ereignen. Für die km-abhängige Ausfallwahrscheinlichkeit konnte mit Hilfe dieses Ausfallmodells die in Bild 4.23 dargestellte Anpassung an die empirischen Ausfalldaten vorgenommen werden.



**Bild 4.23: Angepasste und empirische Ausfallwahrscheinlichkeit (Modell 1)**


Auf Grundlage der ermittelten km-abhängigen Ausfallwahrscheinlichkeit und der zugehörigen Fahrleistungsverteilung werden alle weiteren Schritte der Zuverlässigkeitsprog-

nose durchgeführt. In der Tabelle 4.11 sind die ermittelten Verteilungsparameter für das Steuergerät eingetragen.

**Tabelle 4.11: Geschätzte Parameter Steuergerät (Modell 1)**

	$\mu$	$\sigma$
Fahrleistungsverteilung (Lognormal-Verteilung)	3,68569	0,603499
Anzahl vorgeschädigter Produkte $n_T$ (geschätzt)	206	
	$\alpha$	$\beta$
Km-abhängige Ausfallwahrscheinlichkeit $F_T(s)$ (Weibull-Verteilung)	7,3775 E-03	1,43455


Bestimmt man die Ausfallrate in Abhängigkeit von der Zeit, so zeigt diese ein typisches Frühausfallverhalten. Die zeitabhängige Verteilungsfunktion lässt sich für das entwickelte Modell nicht explizit angeben, sondern kann nur numerisch bestimmt werden. In Bild 4.24. ist der Verlauf der zeitabhängigen Ausfallrate dargestellt.



**Bild 4.24: Zeitabhängige Ausfallrate Steuergerät (Modell 1)**


Die zeitabhängige Ausfallrate steigt innerhalb des ersten Jahres bis zu einem Maximalwert von 0,7/Jahr stark an. Danach nimmt die Ausfallrate stetig ab und erreicht nach zehn Jahren einen Wert von 0,4/Jahr. Die Ausfallneigung eines Produktes, das bereits ein Jahr im Feld ist, nimmt also mit zunehmender Zeit immer weiter ab. Betrachtet man

die zeitabhängige Ausfallwahrscheinlichkeit (Bild 4.25), so kann man erkennen, dass innerhalb der ersten zwei Jahre bereits 72% aller betroffener Produkte ausfallen werden. Vergleicht man diese Schätzung nun mit den tatsächlich innerhalb der 2-jährigen Garantiezeit aufgetretenen Ausfällen, so zeigt sich eine gute Übereinstimmung.



**Bild 4.25: Zeitabhängige Ausfallwahrscheinlichkeit (Modell 1)**

Bezieht man die ermittelten Verteilungsfunktionen auf die gesamte Verkaufsmenge, so erhält man den in Bild 4.26 dargestellten Verlauf der zeitabhängigen Ausfallrate. Diese gilt nur für eine endlich lange Zeitspanne, da davon ausgegangen wird, dass alle nicht betroffenen Teile immun gegen Ausfälle sind.



**Bild 4.26: Zeitabhängige Ausfallrate für gesamte Verkaufsmenge (Modell 1)**

## Ausfallmodell 2

Während der Garantiezeit betrachtet man die gesamte Verkaufsmenge der zu untersuchenden Produkte. Jedes Motorkühlgebläse kann daher auf Grund verschiedener Ursachen ausfallen. Geht man nun, wie in Modell 1 beschrieben, davon aus, dass sich nur Fehler innerhalb einer bestimmten Subpopulation ereignen, so trifft man eine wesentliche Vereinfachung. Man schließt nämlich damit aus, dass Ausfälle in den Garantiedaten enthalten sind, die auf anderen Fehlermechanismen beruhen. Das Ausfallmodell 2 wird daher, um diesen Anteil von möglichen sonstigen Ausfällen ergänzt. Die Grundidee ist hierbei, dass, ähnlich wie bei dem Kupplungsteller, eine Fehlerursache vorhanden ist, die sich auf eine Subpopulation beschränkt und eine weitere Ausfallfunktion, die alle sonstigen möglichen Fehler in der Verkaufsmenge beschreibt. Die Gesamtausfallwahrscheinlichkeit des Systems lässt sich für Ausfallmodell 2 wie folgt definieren:

$$F(s) = \frac{n_{11}}{n} F_{11}(s) - \frac{n_{11}}{n} F_2(s) F_{11}(s) + F_2(s), \quad (4.15)$$

mit

$F_{11}(s)$ : Ausfallwahrscheinlichkeit für Produkte mit Vorschädigung,

$F_2(s)$ : Ausfallwahrscheinlichkeit sonstige Fehlerursachen,

$\frac{n_{11}}{n}$ : Anteil der Produkte mit Vorschädigung (Subpopulation).

Da auch bei diesem Ansatz das Verhältnis  $\frac{n_{11}}{n}$  von Produkten mit Vorschädigung nicht bekannt ist, muss diese Größe ebenfalls, als zusätzlich zu bestimmender Parameter, in die Betrachtung eingefügt werden. Ein wesentliches Problem bei diesem Modell ist die hohe Anzahl an unbekanntem Parametern, die sich unter Umständen nur schwer numerisch bestimmen lassen. Im Falle zweier Weibull-Verteilungen zur Beschreibung der beiden Fehlermöglichkeiten sind insgesamt fünf Parameter zu bestimmen. Außerdem können die aufgetretenen Ausfälle nicht den Fehlerursachen zugeordnet werden. Somit ist eine Separation, wie bei der Analyse des Kupplungstellers, nicht möglich. Die Modellbildung beruht daher auf den subjektiven Kenntnissen über die vorhandenen Fehlermechanismen. In Tabelle 4.12 sind die geschätzten Parameter des Ausfallmodells 2 für km-abhängige Betrachtungen eingetragen.

Tabelle 4.12: Geschätzte Parameter Steuergerät (Modell 2)

	$\mu$	$\sigma$
Fahrleistungsverteilung (Lognormal-Verteilung)	3,68569	0,603499
Anzahl Produkte $n_{11}$ aus der Subpopulation (geschätzt)	175,3	
	$\alpha$	$\beta$
Km-abhängige Ausfallwahrscheinlichkeit $F_{11}(s)$ (Weibull-Verteilung)	6,36581 E-3	1,50737
Km-abhängige Ausfallwahrscheinlichkeit $F_2(s)$ (Weibull-Verteilung)	4,92673 E-6	0,896942

Bild 4.27 und Bild 4.28 zeigen die km-abhängige Ausfallwahrscheinlichkeit und die zugehörige km-abhängige Ausfallrate für das untersuchte Steuergerät.






Bild 4.27: km-abhängige Ausfallwahrscheinlichkeit (Modell 2)



**Bild 4.28: km-abhängige Ausfallrate (Modell 2)**

Bild 4.27 zeigt die gute Anpassung des Modells an die empirischen Werte. Der Übergang von den km-abhängigen Funktionen zur Zeitabhängigkeit ist nur numerisch möglich. Daher lassen sich für die zeitabhängigen Funktionen keine geschlossenen Formen angeben. Bestimmt man die Ausfallrate des Steuergerätes über die Zeit, so ergibt sich der in Bild 4.29 aufgetragene Verlauf.




**Bild 4.29: Zeitabhängige Ausfallrate eines Steuergerätes (Modell 2)**

Die Ausfallrate steigt innerhalb kurzer Zeit an und erreicht ihr Maximum nach etwa vier Monaten. Danach nimmt die Ausfallrate stark ab, bis sie etwa nach vier Jahren einen nahezu konstanten Verlauf hat. Betrachtet man diesen Verlauf makroskopisch, so kann

man von einem typischen Frühausfallverhalten sprechen. Es ist lediglich auffällig, dass es bis zum Aktivieren des Fehlermechanismus etwa vier Monate dauert und nicht schon bei den ersten Betätigungen des Systems zu einem Ausfall kommt. Es lässt sich daher vermuten, dass einige Betriebszyklen (z.B. Erwärmungen) bis zur Beschädigung der Komponente notwendig sind.

In Bild 4.30 ist ein Vergleich der beiden entwickelten Modelle anhand der zeitabhängigen Ausfallraten dargestellt.



**Bild 4.30: Vergleich der zeitabhängigen Ausfallrate für Modell 1 und Modell 2**

Die Ausfallraten zeigen im ersten Jahr fast keinen Unterschied. Danach bleibt die Ausfallrate für Modell 2 auf einem höheren Niveau und fällt weniger stark ab. Beide Funktionen sind ab etwa dem vierten Jahr konstant. D.h. beide Modelle zeigen das gleiche qualitative Ausfallverhalten auf unterschiedlichem Niveau. Auf längere Zeit gesehen dominiert bei Modell 2 die zusätzlich integrierte Ausfallwahrscheinlichkeit  $F_2(s)$  das Ausfallverhalten. Der wesentliche Vorteil von Modell 2 ist, dass es nicht wie Modell 1, nur für einen endlichen Zeitraum definiert ist. Für Modell 2 gilt für  $t \rightarrow \infty$  geht  $R(t) \rightarrow 0$ . Damit lässt sich mit dem Ausfallmodell 2 das Ausfallverhalten der gesamten Verkaufsmenge wesentlich realistischer beschreiben.

Es ist jedoch anzumerken, dass beide Ausfallmodelle auf Annahmen und Vereinfachungen beruhen. Die Vermutung, dass es sich bei den Ausfällen im Wesentlichen um Ausfälle innerhalb einer begrenzten Subpopulation der Grundgesamtheit handelt, beruht auf subjektiv gewonnenen Aussagen über die auftretenden Fehlermechanismen, auf Erfah-

rungen bei der Analyse anderer Produkte (z.B. Kupplungsteller) und dem qualitativen Verlauf der empirischen Lebensdauerverteilung.

Im Folgenden sollen nun ergänzend einige weitere Nutzungsmöglichkeiten für die gewonnen Prognoseergebnisse exemplarisch dargestellt werden. Es handelt sich hierbei um indirekte Nutzungsmöglichkeiten, da sie von den ermittelten Zuverlässigkeitskenngrößen abgeleitet werden.

#### 4.3.4 Weitere Nutzungsmöglichkeiten der Prognoseergebnisse

Die indirekten Nutzungsmöglichkeiten der Zuverlässigkeitsprognose beruhen primär auf der Prognose der zeitabhängigen Ausfallwahrscheinlichkeit. Mit dieser lässt sich die zu erwartende Anzahl von Produkten, die innerhalb eines Zeitintervalls  $\Delta t$  ausfallen bzw. die Anzahl der insgesamt bis zu einem Zeitpunkt  $t$  zu erwartenden kumulierten Ausfälle, prognostizieren.

##### Garantiekosten bei Garantiezeitverlängerung

Die zu erwartenden Garantiekosten hängen von der Anzahl der Garantiefälle, den durchschnittlichen Kosten pro Garantiefall und der Garantiedauer ab. Durch höhere Kundenforderungen und neue Gesetze kann es zur Verlängerung der Garantiezeit kommen. Es ist daher notwendig, schon frühzeitig eine Prognose der Kosten für eine solche Garantiezeitverlängerung anzustellen. Kennt man das zeitabhängige Ausfallverhalten der Produkte und die zugehörigen Garantiekosten, kann es auch aus wettbewerbspolitischer Sicht sinnvoll sein, eine Garantiezeitverlängerung anzustreben. Bisher betrug die Gewährleistungszeit der meisten Produkte ein Jahr, wobei nunmehr mindestens zwei Jahre vorgeschrieben sind und von manchen Kunden (z.B. in den USA) auch längere Garantiezeiten gefordert werden.

Eine praxisnahe Methode zur Abschätzung der Garantiekosten ist in [Pau98] hergeleitet und soll hier beispielhaft angewendet werden. Die anfallenden Garantiekosten  $K$  lassen sich leicht aus

$$K(g) = k \cdot n_a(g) = k \cdot n_0 \cdot F(g), \quad (4.16)$$

mit

- $g$  : Garantiezeit,
- $k$  : Gesamtkosten pro Garantiefall,
- $n_a(g)$  : zu erwartende Anzahl von Garantiefällen,
- $n_0$  : Gesamtverkaufsmenge,




$F(g)$ : Ausfallwahrscheinlichkeit eines Produktes während der Garantiezeit, bestimmen.

Eine Ausweitung der Garantiezeit auf  $c \cdot g$  Jahre ( $c > 1$ ) bedeutet auch ein Anstieg der Garantiekosten. Die Mehrkosten für eine Garantiezeitverlängerung betragen dann:

$$\Delta K = k \cdot n_0 \cdot (F(c \cdot g) - F(g)). \quad (4.17)$$

Bezieht man diese Mehrkosten auf die gesamte Fertigungsmenge, so erhöhen sich die zugehörigen Herstellungskosten eines Produktes nur geringfügig. Es ist anzumerken, dass der Zusammenhang zwischen Garantiezeitverlängerung und Garantiekostenerhöhung nicht linear ist, sondern von der zeitabhängigen Ausfallwahrscheinlichkeit abhängt.

Die prozentuale Entwicklung der Garantiekosten in Abhängigkeit der Garantiezeitverlängerung, ist in Bild 4.31 veranschaulicht ( $t_{gar}$  ist die Garantiezeit).




**Bild 4.31: Änderung der Garantiekosten in Abhängigkeit der Garantiezeitverlängerung**

Aus Bild 4.31 lässt sich erkennen, dass für das Beispiel eine Garantiezeit von 4,5 Jahren etwa zu einer Verdoppelung der Garantiekosten führen würde. Ausgangsbasis ist eine bestehende Garantiezeit von einem Jahr (0% Erhöhung). Verlängert man dagegen die Garantiezeit von einem Jahr auf zwei Jahre, bedeutet dies ein Anstieg der Garantiekosten um 37%.

Stellt man nun die Änderung der Garantiekosten ins Verhältnis zu den Herstellungskosten, d.h. man legt die Mehrkosten auf die Gesamtfertigungsmenge um, so ergibt sich der

in Bild 4.32 dargestellte Zusammenhang. Dabei wird davon ausgegangen, dass die Kosten für einen Garantiefall etwa das Sechsfache der Herstellungskosten betragen.



**Bild 4.32: Prozentuale Erhöhung der Herstellungskosten abhängig von Garantiezeitverlängerung**

Erhöht man die Garantiezeit von einem auf zwei Jahre, so steigen für das Beispiel die Herstellungskosten um durchschnittlich 0,04% an. Bei einer Ausweitung der Garantiezeit auf vier Jahre werden sich die Herstellungskosten um ca. 0,095% erhöhen. Mit Hilfe der vorgestellten Vorgehensweise lassen sich auf einfache Weise praktische Abschätzungen der Kosten bei etwaigen Garantiezeitverlängerungen durchführen.

### **Serienersatzbedarf**

Unter dem Serienersatz soll die Menge von Produkten verstanden werden, die zusätzlich während der Serienfertigung als Ersatzteile hergestellt werden. Der Ersatzteilbedarf ist von der Gesamtverkaufsmenge, der Verteilung der Verkaufsmengen auf die einzelnen Herstellungsjahre und der zugehörigen Produktionsdauer abhängig. Ein weiterer wesentlicher Faktor bei der Berechnung des Serienersatzbedarfs ist die Verschrottung alter Fahrzeuge. In der Tabelle 4.13 sind die durchschnittlichen Bestandsanteile von Fahrzeugen in Abhängigkeit von der Zulassungsdauer nach VDA aufgetragen [VDA96]. Dieser Anteil von verschrotteten Fahrzeugen muss ebenfalls bei der Berechnung des Serienersatzbedarfs berücksichtigt werden.

Tabelle 4.13: Durchschnittlicher Bestandsanteil für PKW

Alter [Jahr]	0	1	2	3	4	5	6	7	8
Anteil [%]	100.0	99.9	99.5	98.7	97.6	96.2	94.4	91.6	87.7
Alter [Jahr]	9	10	11	12	13	14	15	16	17
Anteil [%]	81.9	74.5	65.8	56.2	45.8	35.8	26.1	18.6	12.6

Der zu erwartende Serienersatzbedarf lässt sich mit folgender Gleichung abschätzen [Pau98]:

$$M_S := \sum_{i=1}^{t_E} n_0(i) \cdot \sum_{j=i}^{t_P} c_{j-i} \cdot (F(j-i+1) - F(j-i)), \quad (4.18)$$

mit

$t_E$ : Zeitpunkt Serienende,

$t_P$ : Zeitpunkt nach Serienende, bis zu dem produziert wird,

$n_0(i)$ : Fertigungsmenge im  $i$ -ten Jahr,

$c$ : Bestandsanteil von Fahrzeugen.

Werden nach Serienende keine Teile mehr gefertigt, ist  $t_P = t_E$ . Im Folgenden wird beispielhaft der Serienersatzbedarf für den Wischermotor Wischer\_alt\_1 ermittelt, der über einen Zeitraum von vier Jahren gefertigt wurde. Die Fertigungsmengen sind in Tabelle 4.14 exemplarisch eingetragen.

Tabelle 4.14: Jährliche Fertigungsmengen für einen Wischermotor (Beispiel)

Jahr	1	2	3	4
Fertigungsmenge	350 000	400 000	580 000	500 000

Die Gesamtfertigungsmenge beträgt 1 830 000 Stück. Mit Hilfe der vorstehenden Gleichung lässt sich für  $t_P = t_E = 4$  Jahre ein zu erwartender Serienersatzbedarf von 298 Teilen berechnen. Grundlage der Schätzung ist die zuvor mit Hilfe des Prognosemodells bestimmte zeitabhängige Ausfallwahrscheinlichkeit des entsprechenden Wischermotors.

Eine weitere indirekte Nutzungsmöglichkeit der Prognoseergebnisse ist die Abschätzung der Endbevorratungsmenge.

### Endbevorratungsmenge

Im Rahmen der Nachlieferpflicht müssen nach Möglichkeit vor dem Abbau oder der Umrüstung der Serieneinrichtungen die Endbevorratungsmengen gefertigt und sachgerecht eingelagert werden. Ziel ist es, die benötigte Endbevorratungsmenge möglichst genau zu bestimmen, da sowohl eine zu geringe wie auch eine zu hohe Anzahl von Teilen enorme Kosten verursachen können. Die Endbevorratungsmenge lässt sich leicht durch eine Modifikation der Formel für den Serienersatzbedarf bestimmen. Bezeichnet man die Nachlieferpflicht nach Serienende mit  $t_N$  und ist  $t_p < t_N$ , ergibt sich folgende Gleichung für die Endbevorratungsmenge:

$$M_E := \sum_{i=i}^{t_E} n_0(i) \cdot \sum_{j=t_p+1}^{t_N} c_{j-i} \cdot (F(j-i+1) - F(j-i)). \quad (4.19)$$

Für das eingeführte Beispiel des Wischermotors Wischer\_alt\_1 ergibt sich bei einer angenommenen Nachlieferpflicht von 10 Jahren eine Endbevorratungsmenge von 318 Teilen.

Der gesamte Ersatzbedarf  $M_{ges}$  ergibt sich durch Addition des Serienersatzbedarfs und der Endbevorratungsmenge. Er lässt sich auch direkt durch folgende Formel bestimmen:


$$M_{ges} := M_S + M_E = \sum_{i=i}^{t_E} n_0(i) \cdot \sum_{j=i}^{t_N} c_{j-i} \cdot (F(j-i+1) - F(j-i)). \quad (4.20)$$

Für das Beispiel ergibt sich ein gesamter Ersatzbedarf von 616 Teilen.

Die durchgeführten Analysen und die daraus gewonnen Ergebnisse zeigen, wie sich auf Basis des entwickelten allgemeinen Ausfallmodells die Zuverlässigkeit beliebiger Kfz-Komponenten, mit beliebigen Fehlermechanismen, prognostizieren lässt. Es wurde gezeigt, wie für unterschiedliche Fragestellungen individuelle Ausfallmodelle für die untersuchten Systeme entwickelt wurden. Das allgemeine Zuverlässigkeitsprognosemodell ist ein neues Werkzeug zur Wissensgenerierung für den gesamten Produktentstehungsprozess und eine wichtige Entscheidungshilfe für die Produktentwicklung und das Management. Die Ergebnisse der Zuverlässigkeitsprognose lassen sich, wie an den Beispielen gezeigt, für weiter Fragestellungen verwenden und leicht weitere Nutzungsmöglichkeiten entwickeln.

## 5 Ein neues Zuverlässigkeitsprognosemodell für unvollständige Daten

Die zu einem bestimmten Zeitpunkt vorhandenen Garantiedaten enthalten im zeitnahen Fall noch nicht die vollständigen Informationen über das tatsächliche Ausfallverhalten eines Produktes während der Garantiezeit. Diese Informationslücke muss bei einer Zuverlässigkeitsprognose auf Basis von Garantiedaten berücksichtigt werden [Myr03]. Wobei im Folgenden unter zeitnahen Garantiedaten, solche Daten verstanden werden, bei denen die Zeitspanne zwischen Fertigungs-, Zulassungs-, Ausfall-, Registrierdatum und dem Zeitpunkt der Analyse relativ gering ist. Im Weiteren werden nun die zu berücksichtigenden Einflüsse modelliert und eine neue Vorgehensweise entwickelt, die es ermöglicht, eine Zuverlässigkeitsprognose auch bei unvollständigen Informationen durchzuführen. Im Folgenden versteht man unter den Garantiedaten, die Daten, die zu einem bestimmten Betrachtungszeitpunkt  $t_B$  ermittelt wurden. In Bild 5.1 werden die zeitlichen Zusammenhänge eines Ausfalls noch einmal verdeutlicht.




**Bild 5.1: Zeitliche Zusammenhänge für einen Garantiefall**

Ein betrachtetes System wird in einem Fertigungsmonat  $t_F$  gefertigt. Mit dem Zeitpunkt  $t_Z$ , der Zulassung des Fahrzeugs, beginnt die Garantiezeit des Produktes. Der Ausfall eines Systems ereignet sich im Ausfallmonat  $t_A$ . Zum Zeitpunkt  $t_R$  wird der aufgetretene Garantiefall in einer Garantiedatenbank registriert.

## 5.1 Einflussfaktoren

### 5.1.1 Zulassungsverzug

Der Zulassungsverzug beschreibt die Dauer zwischen der Fertigung eines Produktes und der Zulassung des Fahrzeuges. Der Zulassungsverzug addiert sich aus allen Lager-, Transport- und Montagezeiten. Mit der Zulassung des Fahrzeuges beginnt auch die Garantiezeit des Produkts. Es ist daher wichtig, den Anteil der Fahrzeuge zu schätzen, der zu einem bestimmten Zeitpunkt bereits zugelassen ist und sich noch innerhalb der Garantiezeit befindet. Der für ein Produkt typische Zulassungsverzug lässt sich näherungsweise aus den in den Garantiedaten enthaltenen Informationen zum Fertigungs- und Zulassungsmonat beschreiben. Hierzu eignet sich als Verteilungsmodell die Lognormalverteilung. Die Parameter der Lognormalverteilung werden mit der Maximum-Likelihood-Methode geschätzt. Das Bild 5.2 zeigt die empirische und die theoretische Verteilungsfunktion  $F_Z(t)$  des Zulassungsverzugs.



**Bild 5.2: Verteilungsfunktionen des Zulassungsverzugs**

In Bild 5.2 lässt sich beispielsweise ablesen, dass innerhalb der ersten vier Monate etwa 70% der gefertigten Produkte in einem zugelassenen Fahrzeug verbaut sind.

Eine weitere wichtige Größe für die Zuverlässigkeitsprognose ist die Gesamtzahl der Fahrzeuge  $n_Z(j)$ , die bis zu einem Monat  $j$  zugelassen sind. Sie bildet die Grundgesamtheit aller weiteren Untersuchungen. Die Menge  $n_Z(j)$  lässt sich mit folgender Gleichung bestimmen:

$$n_Z(j) = \sum_{i=1}^j n_F(i) \cdot F_Z(j-i+1) \quad \forall i \leq j, \quad i, j \in N, \quad (5.1)$$

mit

$n_F(i)$ : Fertigungsmenge im Monat  $i$ ,

$F_Z$ : Verteilung des Zulassungsverzugs,


$i$ : Fertigungsmonat,

$j$ : Betrachtungsmonat.

### 5.1.2 Meldeverzug

Der Meldeverzug charakterisiert die Zeitspanne zwischen dem Ausfall eines Produktes und der Registrierung dieses Ausfalls in der Garantiedatenbank, d.h. dem Zeitpunkt, ab dem der Ausfall in einer Auswertung der Garantiedaten frühestens erscheint und damit für die Prognose zur Verfügung steht. Die Ursachen für diesen Verzug sind meist organisatorischer Natur.

Mit Hilfe der bereits bekannten Garantiefälle kann die Verteilungsfunktion  $F_M(t)$  des Meldeverzugs für das zu untersuchende Produkt geschätzt werden. Zur Beschreibung des Meldeverzugs eignet sich ebenfalls die Lognormalverteilung, die mit Hilfe der Maximum-Likelihood-Methode an die empirischen Daten angepasst wird. Bild 5.3 zeigt die empirische und theoretische Verteilungsfunktion des Meldeverzugs einer ausgewählten Kfz-Komponente.



**Bild 5.3: Verteilungsfunktionen des Meldeverzugs**

Mit der ermittelten Verteilungsfunktion lässt sich der Anteil von Ausfällen bestimmen, der nach einer bestimmten Zeit in der Garantiedatenbank erfasst ist. So werden nach 3 Monaten etwa 60% aller aufgetretenen Garantiefälle in einer Abfrage der Garantiedaten

erscheinen. Auf Grund dieses Meldeverzugs müssen die aus der Garantiedatenbank zum Analysezeitpunkt  $t_B$  ermittelten Ausfälle korrigiert werden, da diese noch nicht alle real aufgetretenen Ausfälle repräsentieren. Die Gesamtzahl von Garantiefällen für einen bestimmten Ausfallmonat  $t_A$  und eine Fahrstrecke  $s$  in Abhängigkeit eines Betrachtungszeitpunktes  $t_B$  lässt sich nach folgender Gleichung bestimmen:

$$n_{t_A, t_B}(s) = \frac{n_{t_A}(s)}{F_M(t_B - t_A)}, \quad (5.2)$$

mit

- $n_{t_A, t_B}(s)$ : Korrigierte Ausfallhäufigkeit mit der Fahrstrecke  $s$  für Ausfallmonat  $t_A$  im Betrachtungsmonat  $t_B$ ,
- $n_{t_A}(s)$ : Registrierte Ausfälle mit der Fahrstrecke  $s$  im Ausfallmonat  $t_A$ ,
- $F_M(t_B - t_A)$ : Anteil der Ausfälle, der zum Betrachtungszeitpunkt bereits erfasst ist.

Durch Aufsummieren der korrigierten Ausfallhäufigkeiten für eine bestimmte Fahrstrecke  $s$  über alle Ausfallmonate  $t_A$ , erhält man die Gesamtzahl  $N_M(s)$  der real aufgetretenen Ausfälle mit der entsprechenden Laufleistung. Es gilt:

$$N_M(s) = \sum_{t_A} n_{t_A, t_B}(s) = \sum_{t_A} \frac{n_{t_A}(s)}{F_M(t_B - t_A)}. \quad (5.3)$$

### 5.1.3 Korrigierte Anwärterberechnung

Bei dem Standard-Zuverlässigkeitsprognosemodell geht man davon aus, dass alle betrachteten Fertigungsmengen bereits die Garantiezeit absolviert haben. Bei zeitnahen Garantiedaten ist dies jedoch nicht immer der Fall. So kann es sein, dass Produkte aus einem Zulassungsmonat ausfallen, für die die Garantie noch über den Betrachtungszeitpunkt hinaus bestehen würde. Das heißt, die verbleibenden Produkte aus dem gleichen Zulassungsmonat befinden sich noch innerhalb der Garantiezeit. Dies hat Einfluss auf die Berechnung der Anwärter und muss entsprechend berücksichtigt werden. So muss bei zeitnahen Garantiedaten bei der Anwärterberechnung, die für den jeweiligen Zulassungsmonat spezifische Fahrleistungsverteilung  $L_d(s)$  bestimmt werden. Es folgt:



$$L_d(s) = L_G\left(\frac{s \cdot g}{d}\right), \quad d = \min\{t_B - t_Z, g\}, \quad (5.4)$$

mit

$L_G$ : Laufleistungsverteilung für die Garantiezeit,

$g$ : Garantiedauer,

$t_Z$ : Zulassungsmonat.

Auf Basis dieser Umrechnung kann nun, für jeden Zulassungsmonat, die korrigierte Anzahl der km-abhängigen Ausfälle berechnet werden. Es gilt:

$$n_{t_Z,k}(s) = \frac{n_{t_Z}(s)}{1 - L_d(s)}, \quad (5.5)$$

mit

$n_{t_Z,k}(s)$ : Korrigierte Ausfallhäufigkeit bei der Fahrstrecke  $s$  unter Berücksichtigung von  $d$ ,

$n_{t_Z}(s)$ : Ausfälle bei der Fahrstrecke  $s$  für den Zulassungsmonat  $t_Z$ .

Um nun die Gesamtzahl  $N_{AN,k}(s)$  an Ausfällen bei einer Fahrstrecke  $s$  für alle Zulassungsmonate zu bestimmen, müssen die korrigierten Ausfälle für die einzelnen Fahrstrecken über alle Zulassungsmonate summiert werden. Es folgt:

$$N_{AN,k}(s) = \sum_{t_Z} n_{t_Z,k}(s) = \sum_{t_Z} \frac{n_{t_Z}(s)}{1 - L_d(s)}. \quad (5.6)$$

## 5.2 Modifiziertes Prognosemodell

Im Folgenden werden alle zuvor beschriebenen Einflussfaktoren in das Zuverlässigkeitsprognosemodell integriert. Die Anzahl von Ausfällen  $n_k(s)$ , die bei einer bestimmten Fahrstrecke  $s$  insgesamt zu erwarten sind, lässt sich dann mit folgender Summenformel bestimmen:

$$n_k(s) = \sum_{t_Z, t_A} \frac{n_{t_Z, t_A}(s)}{(F_M(t_B - t_A)) \cdot (1 - L_d(s))}, \quad (5.7)$$

mit

$n_{t_Z, t_A}$ : Gesamtzahl Ausfälle bei Fahrstrecke  $s$  mit Zulassungsmonat  $t_Z$  und Ausfallmonat  $t_A$  aus den zeitnahen Garantiedaten.

Die Berechnung der korrigierten empirischen Ausfallwahrscheinlichkeit  $\tilde{F}_k(s)$  erfolgt durch sukzessive Kumulation der ermittelten Ausfallzahlen bezogen auf die zum Betrachtungszeitpunkt vorhandene Zulassungsmenge  $n_Z$  (Gleichung (5.1)). Es folgt:

$$\tilde{F}_k(s) = \frac{1}{n_Z} \sum_{\zeta \leq s} n_k(\zeta) = \frac{1}{n_Z} \sum_{\zeta \leq s} \left( \sum_{t_Z, t_A} \frac{n_{t_Z, t_A}(\zeta)}{(F_M(t_B - t_A)) \cdot (1 - L_d(\zeta))} \right), \quad (5.8)$$

mit

$\zeta$ : gefahrene Strecke.

## 5.3 Ergebnisse

Das entwickelte neue Verfahren zur Prognose der Zuverlässigkeit bei unvollständigen Garantiedaten wurde zum einen mit Hilfe von Simulationen verifiziert und zum anderen auf reelle Garantiedaten angewendet. Die Vorgehensweise bei der Simulation und die daraus gewonnenen Ergebnisse werden im Folgenden dargestellt. Im Anschluss wird die Anwendung auf die Garantiedaten eines aktuellen, zur Zeit der Analyse noch gefertigten, Wischermotors gezeigt.

### 5.3.1 Simulation

Ziel der Simulation ist es, die Genauigkeit des modifizierten Prognosemodells zu ermitteln und dessen Anwendbarkeit zu zeigen. Alle Simulationen wurden mit der mathematischen Entwicklungssoftware Mathematica™ Version 4.0 erstellt und durchgeführt.

Zur Erzeugung einer realitätsnahen Stichprobe werden für vorgegebene Verteilungsfunktionen des Meldeverzugs, des Zulassungsverzugs, der Fahrleistung bezogen auf die Garantiedauer und der gefahrenen Strecke bis zum Ausfall, voneinander unabhängige Zufallszahlen generiert. Die Zufallszahlen werden dann zufällig miteinander kombiniert, so dass Datensätze mit jeweils vier unabhängigen Merkmalen vorliegen. Tabelle 5.1 zeigt ein Beispiel für simulierte und daraus abgeleitete Größen eines Datensatzes.

Tabelle 5.1: Beispiel simulierter und abgeleiteter Daten

Zufallszahlen				abgeleitet
Zulassungsverzug $\Delta t_Z$	Fahrleistung Garantiezeit $s_{LG}$	Fahrstrecke bis Ausfall $s$	Meldeverzug $\Delta t_M$	Dauer bis zum Ausfall $\Delta t_A = \frac{s}{s_{LG}}$
1	10	2	1	2,4
1	12	3	1	3
3	9	1	2	1,3
.	.	.	.	.
.	.	.	.	.
.	.	.	.	.

Aus den generierten Datensätzen sind dann solche auszuwählen, die folgendes Kriterium erfüllen:

$$t_F + \Delta t_Z + \Delta t_A + \Delta t_M \leq t_B. \quad (5.9)$$

Die ausgewählten Datensätze entsprechen den Garantiefällen, die bei einer Analyse zum Betrachtungszeitpunkt  $t_B$  auf Basis der vorgegebenen Verteilungsfunktionen für die Analyse zur Verfügung stehen. Sie stellen die Eingangsgrößen des modifizierten Prognosemodells dar.

Die Verteilungsfunktionen der Zufallszahlen werden bei den Simulationen so gewählt, dass mindestens 50 Datensätze analysiert werden können. Die Parameterschätzung erfolgt mit drei verschiedene Methoden. Nach der Anwärterberechnung wird die lineare Regression und die Methode der kleinsten Quadrate eingesetzt. Zusätzlich wird als alternative Vorgehensweise ein leicht modifizierter Ansatz ohne Anwärterberechnung auf Basis der Maximum-Likelihood-Methode verwendet.

Die Simulationen werden für vier Szenarien mit unterschiedlichen km-abhängigen Ausfallwahrscheinlichkeiten durchgeführt. Jedes Szenario wird 100-mal simuliert und entsprechend der entwickelten Methode ausgewertet. Als Bewertungsgrößen dienen die Mittelwerte  $\bar{\alpha}$  bzw.  $\bar{\beta}$  der geschätzten Parameter und als Maß für die Streuung die zugehörige Standardabweichung  $\sigma$  und der Variationskoeffizienten  $v$ . Des Weiteren werden die Konfidenzintervalle KI für den Mittelwert der geschätzten Parameter angege-

ben. Die folgende Tabelle 5.2 zeigt beispielhaft die Simulationsergebnisse für Szenario I. Die vollständigen Ergebnisse der Simulationen und Beschreibung der verwendeten Szenarien befinden sich im Anhang.

**Tabelle 5.2: Simulationsergebnisse für Szenario I (Sollwerte  $\alpha = 0,003981$ ,  $\beta = 0,4$ )**

Methode	$\bar{\alpha}$	$\sigma_{\bar{\alpha}}$	$v_{\bar{\alpha}}$	$KI(\bar{\alpha})_{0,95}$	$\bar{\beta}$	$\sigma_{\bar{\beta}}$	$v_{\bar{\beta}}$	$KI(\bar{\beta})_{0,95}$
LR	0,0039796	0,00087577	0,220066	[0,00380493; 0,00415428]	0,394538	0,0941135	0,238541	[0,375768; 0,413309]
KQ	0,00382598	0,00135398	0,353892	[0,00355309; 0,00409886]	0,434297	0,205548	0,47329	[0,392869; 0,475724]
ML	0,00265491	0,00374298	1,40983	[0,00189652; 0,00341331]	0,551692	0,0602128	0,109142	[0,539492; 0,563892]

Die Ergebnisse der Simulationen zeigen, dass in Abhängigkeit von dem verwendeten Schätzverfahren, das für unvollständige Garantiedaten entwickelte Prognosemodell im Mittel sehr gute Schätzwerte für die Zuverlässigkeitskenngrößen ergibt. Für alle Szenarien zeigt sich, dass die lineare Regression (LR) die besten Ergebnisse liefert und im Vergleich zur Methode der kleinsten Quadrate (KQ) eine geringere Streuung besitzt. Die Schätzungen mit der Maximum-Likelihood-Methode (ML) sind für alle untersuchten Szenarien unzureichend. Dies lässt sich dadurch begründen, dass die Maximum-Likelihood-Methode generell bei Stichproben, die ein großes Verhältnis zwischen ausgefallenen und zensierten Daten aufweisen, meist schlechtere Ergebnisse liefert als andere Methoden.

### 5.3.2 Felddaten

Das modifizierte Prognosemodell für unvollständige Garantiedaten wurde auch für verschiedene reale Garantiedaten angewendet. Als Beispiel sollen im Folgenden die Analyseergebnisse eines Wischermotors dargestellt werden. Der Motor wurde zum Zeitpunkt der Analyse noch gefertigt. Aus diesem Grund ist es notwendig, das modifizierte Modell für die Zuverlässigkeitsprognose zu verwenden. In der folgenden


Tabelle 5.3 sind die Ergebnisse der Parameterschätzungen für die zu bestimmenden Verteilungsfunktionen dargestellt. Als Ausfallmodell wird für die Analyse ein einfaches Ausfallmodell gewählt. Zur Beschreibung der km- und zeitabhängigen Zuverlässigkeitskenngrößen werden Weibull-Verteilungen verwendet. Der Zulassungs- und Melde-

verzug des untersuchten Motors kann mit Hilfe der logarithmischen Normalverteilung beschrieben werden.

**Tabelle 5.3: Ergebnisse Parameterschätzungen für zeitnahe Daten**


	$\mu$	$\sigma$
Fahrleistungsverteilung (logarithmische Normalverteilung)	2,73415	0,522124
Zulassungsverzug (logarithmische Normalverteilung)	0,351481	0,396497
Meldeverzug (logarithmische Normalverteilung)	0,363468	0,372006
	$\alpha$	$\beta$
Km-abhängige Kenngrößen (Weibull-Verteilung)	0,000103635	0,422153
zeitabhängige Kenngrößen (Weibull-Verteilung)	0,000336767	0,422135

In Bild 5.4 ist die korrigierte empirische und die angepasste theoretische Verteilungsfunktionen für die Ausfallwahrscheinlichkeiten des untersuchten Wischermotors aufgetragen.



**Bild 5.4: Empirische und angepasste Verteilungsfunktion der km-abhängigen Ausfallwahrscheinlichkeit**

Die gleichen Garantiedaten werden im Weiteren auch mit Hilfe des Standard-Zuverlässigkeitsprognosemodells, das die Unvollständigkeit der Daten nicht berücksichtigt, ausgewertet. Bei der Standard-Analyse geht man davon aus, dass die gesamte betrachtete Fertigungsmenge zum Zeitpunkt der Analyse bereits die Garantiezeit überschritten hat und dass alle aufgetretenen Ausfälle in dem Garantiedatensatz enthalten sind. Für die analysierten Garantiedaten ergibt sich der in Bild 5.5 dargestellte Verlauf der km-abhängigen Ausfallraten.



**Bild 5.5: Vergleich km-abhängige Ausfallraten**

Für das gewählte Beispiel mit relativ kurzem Betrachtungszeitraum zeigt sich, dass eine Prognose nach dem Standard-Modell die Ausfallrate wesentlich unterschätzt und damit zu falschen Schlussfolgerungen führen kann. Garantiedaten bei denen eine Unvollständigkeit vermutet bzw. bekannt ist, sollten daher mit dem für zeitnahe Garantiedaten entwickelten Zuverlässigkeitsprognosemodell analysiert werden. Für längere Betrachtungszeiträume geht das modifizierte Modell in das Standard-Zuverlässigkeitsprognosemodell über. Die Einflüsse des Zulassungs- und Meldeverzugs werden vernachlässigbar klein, und auch die Anwärterberechnung entspricht dann näherungsweise dem Standard-Ansatz.

## **6 Erweitertes neuronales Zuverlässigkeitsprognosemodell**

Die Zuverlässigkeit von Komponenten und Baugruppen im Kraftfahrzeug ist häufig von weiteren Einflussgrößen, wie z.B. der Temperatur, der Feuchtigkeit oder den Vibrationen am Einbauort, abhängig. Die Ermittlung der funktionalen Zusammenhänge zwischen den Zuverlässigkeitskenngrößen und den möglichen Einflussgrößen ist oft schwierig und kann meist nur durch eine genaue und umfangreiche Untersuchung der wirkenden Fehlermechanismen und verwendeten Materialien erfolgen.

In der Praxis werden zur Modellierung von Temperatur- oder allgemeinen Umwelteinflüssen häufig theoretische Modelle, wie das Arrhenius- oder das Eyring-Modell verwendet, wobei der Nachweis der Anwendbarkeit häufig vernachlässigt wird.

Ziel ist es nun, ein erweitertes und in der Praxis leicht anwendbares Modell zu entwickeln, das es erlaubt, beliebige Einflüsse auf die Zuverlässigkeit von Baugruppen und Komponenten im Kraftfahrzeug zu beschreiben. Zunächst wird ein Überblick über bestehende, vorwiegend statistische Methoden gegeben. Als Alternative hierzu wird ein neuer neuronaler Ansatz entwickelt und auf Ausfalldaten von Wischermotoren angewendet. Die mit Hilfe eines optimierten neuronalen Modells gewonnenen Analyseergebnisse werden anschließend diskutiert.

### **6.1 Statistischer Ansatz**

Die Modellierung von Einflussgrößen auf Wahrscheinlichkeitsfunktionen ist ein umfangreiches Gebiet der Statistik. Die Grundlage solcher statistischer Ansätze bilden die Regressionsmodelle.

#### **6.1.1 Generalisiertes Lineares Regressionsmodell**

Die Regressionsanalyse ist ein Verfahren, welches die Abhängigkeiten von endogenen und exogenen Variablen modelliert. Die unabhängigen (exogenen) Variablen werden mit  $x_i$  und die abhängige (endogene) Variable mit  $y$  bezeichnet. Das Ziel der Regression ist es, die Auswirkungen der Variablen  $x_i$  auf  $y$  vorherzusagen oder zu klassifizieren. Oft werden Regressionsansätze auch zum Testen von Hypothesen über die funktionalen Zusammenhänge zwischen den Variablen verwendet.

Ein generalisiertes lineares Regressionsmodell besitzt für die Variablen  $x_1, x_2, \dots, x_k$  und die unbekannt Parameter  $\beta_0, \beta_1, \dots, \beta_p$  die Form:

$$y = \beta_0 v_0 + \beta_1 v_1 + \beta_2 v_2 + \dots + \beta_p v_p + \varepsilon, \quad (6.1)$$

wobei  $v_0 = 1$  und jedes weitere  $v_j$ , mit  $j = 1, 2, \dots, p$ , eine beliebige Funktion von  $x_1, x_2, \dots, x_k$  ist und  $\varepsilon$  einen zufälligen Fehlers kennzeichnet (Residuum). Es gilt:

$$v_j = v_j(x_1, x_2, \dots, x_k). \quad (6.2)$$

Durch geeignete Transformationen können viele Regressionsmodelle in die generalisierte lineare Form (Gleichung (6.1)) überführt werden. Mögliche Transformationen sind beispielsweise [Dra81]:

- polynomiale Modelle beliebiger Ordnung,
- reziproke Transformationen,
- logarithmische Transformationen,
- Wurzel-Transformationen,
- multiplikative Modelle,
- exponentielle Modelle.

Mit Hilfe des generalisierten linearen Regressionsmodells lassen sich eine Vielzahl von Problemen erfolgreich lösen. Es gibt jedoch auch Situationen, in denen ein solches Modell nicht geeignet ist, beispielsweise wenn zusätzliche Informationen über die tatsächlichen Abhängigkeiten zwischen endogenen und exogenen Variablen vorhanden sind. Belässt man solche, oft nichtlinearen Zusammenhänge in dem Modell und führt keine Transformationen durch, spricht man auch von nichtlinearen Regressionsmodellen. Einen allgemeinen Überblick zu den generalisierten linearen Regressionsmodellen und deren Anwendung findet man u.a. in [McC90, Mye02].

### 6.1.2 Spezielle Regressionsmodelle

Weitere spezielle Regressionsmodelle, die für die Analyse von Ausfalldaten verwendet werden, sind das exponentielle Regressionsmodell, das Weibull-Regressionsmodell, das Cox-Regressionsmodell und das SAFT-Regressionsmodell. Diese Modelle werden im Folgenden kurz dargestellt.

Die Grundannahme der weiteren Betrachtungen ist, dass die Lebensdauer  $T$  einer Komponente oder Baugruppe von exogenen Variablen abhängt. Bei der Analyse werden die



Ausfallzeiten  $t > 0$  und ein Vektor  $z = (z_1, z_2, \dots, z_k)$  von zugehörigen Kovariablen beobachtet. Der Vektor  $z$  kann dabei sowohl quantitative als auch rein qualitative Daten enthalten. Man unterscheidet bei der Zuverlässigkeitsanalyse die erklärenden Variablen in:

- stetige Variablen (metrisch): z.B. Stress, Temperatur, Spannung und Druck,
- diskrete Variablen (ordinal): z.B. Härtegrad oder Anzahl der gleichzeitigen Systemnutzer bzw. -bediener.
- kategorielle Variablen (nominal): z.B. Hersteller, Designvariante oder Ort.

Ein **exponentielles Regressionsmodell** erhält man, wenn die Ausfallrate  $h(t)$  eine Funktion der Kovariablen  $z$  ist. Die zugehörige Ausfallrate ist dann:

$$h(t; z) = \lambda(z). \quad (6.3)$$

Die Funktion  $\lambda(z)$  kann auf verschiedene Weisen parametrisiert werden. Im Falle einer linearen Abhängigkeit,  $z \kappa$ , folgt

$$h(t; z) = \lambda \cdot c(z \kappa), \quad (6.4)$$

mit  $\kappa^T = (\kappa_1, \kappa_2, \dots, \kappa_k)$  als Vektor von Regressionskoeffizienten,  $\lambda$  ist konstant und  $c$  ist eine zu spezifizierende Funktion. Praktische Beispiele für die Funktion  $c$  sind  $c(x) = 1 + x$ ,  $c(x) = (1 + x)^{-1}$  und  $c(x) = \exp(x)$ . Unter Verwendung der dritten Gleichung ergibt sich für die Ausfallrate eines exponentiellen Regressionsmodells folgende Gleichung:

$$h(t; z) = \lambda e^{z \kappa}. \quad (6.5)$$

Entsprechend dem vorgestellten exponentiellen Regressionsmodells lassen sich auch Regressionsmodelle für die Weibull-Verteilung erstellen, im Folgenden kurz als **Weibull-Regression** bezeichnet. Bei der Weibull-Verteilung können beide Parameter in Abhängigkeit von Kovariablen ausgedrückt werden. In [Ans94] wird ein Weibull-Regressionmodell mit abhängigem Parameter  $\alpha$  vorgestellt. Für die Ausfallrate eines solchen Modells unter Annahme einer exponentiellen Funktion  $c$  ergibt sich dann:

$$h(t; z) = e^{z \kappa} \beta \cdot t^{\beta-1}. \quad (6.6)$$

Ein weiteres weit verbreitetes Regressionsmodell, das oft für die Analysen von Patientendaten in der medizinischen Statistik verwendet wird, ist das „proportional hazards model“. Das Modell wird häufig auch nach seinem Begründer **Cox-Regressionmodell**

genannt. Ist  $h(t; z)$  die Ausfallrate eines Individuums zum Zeitpunkt  $t$  mit den Kovariablen  $z$ , dann gilt für die Ausfallrate des „proportional hazards model“ [Cox72]:

$$h(t; z) = \lambda_0(t) e^{z \cdot \kappa}, \quad (6.7)$$

mit  $\lambda_0(t)$  als nicht spezifizierte Grund- oder Basis-Ausfallrate. Bei diesem Modell wirken die Kovariablen multiplikativ auf die Ausfallrate. Die bereits für die Weibull- und Exponentialverteilung vorgestellten Regressionsmodelle lassen sich aus dem Cox-Regressionsmodell ableiten und gehören damit ebenfalls zu den „proportional hazards models“:

Das **SAFT-Regressionsmodell** (scale-accelerated failure time) beschreibt die Effekte der erklärenden Variable  $z$  auf die Lebensdauer mit Hilfe eines Zeitraffungsfaktors  $RF$  als Funktion von  $z$ . Es gilt:

$$T(z) = \frac{T(z_0)}{RF(z)}, \quad RF(z) > 0, \quad RF(z_0) = 1. \quad (6.8)$$

$T(z)$  beschreibt die Lebensdauer unter den Bedingungen  $z$  und  $T(z_0)$  die Lebensdauer unter Normalbedingungen  $z_0$ . Typische Formen des Zeitraffungsfaktors sind:

- für skalare Größen von  $z$ :

$$RF(z) = \frac{1}{e^{z \cdot \kappa}}, \quad \text{mit } z_0 = 0,$$

- für vektorielle Größen  $z = (z_1, z_2, \dots, z_k)$ :

$$RF(z) = \frac{1}{e^{(z_1 \cdot \kappa_1 + z_2 \cdot \kappa_2 + \dots + z_k \cdot \kappa_k)}}, \quad \text{mit } z_0 = 0.$$

Für  $RF > 1$  ergibt sich eine Zeitraffung, d.h. die Zeit läuft schneller unter den Bedingungen  $z$  als unter  $z_0$ , daraus folgt, dass  $T(z) < T(z_0)$  ist. Für  $0 < RF < 1$  ist  $T(z) > T(z_0)$ . Es findet dann eine Verlangsamung bzw. Streckung der Lebensdauer statt.

Typische SAFT-Regressionsmodelle, die bei der Analyse von Lebensdauerdaten verwendet werden, sind das Arrhenius- und das Eyring-Modell. Der Zeitraffungsfaktor des **Arrhenius-Modells** ist:

$$RF_{AR} = e^{\frac{E_a}{k_B} \left( \frac{1}{TK_0} - \frac{1}{TK} \right)}, \quad (6.9)$$

mit  $k_B = 8,63 \cdot 10^{-7} \frac{\text{eV}}{\text{oK}}$  (Boltzmann-Konstante) und  $E_a$  als Aktivierungsenergie in eV.

$TK$  kennzeichnet die Temperatur in °K. Das Arrhenius-Modell ist nicht für alle Temperaturraffungsprobleme anwendbar und gibt nur innerhalb einer begrenzten Temperaturspanne adäquate Ergebnisse.

Das **Eyring-Modell** beruht auf dem aus der Quantenmechanik abgeleiteten Prinzip, dass thermische Beeinflussungen Oxidationen hervorrufen. Mit dem Eyring-Modell lässt sich die Reaktionsgeschwindigkeit in Abhängigkeit von der Temperatur darstellen. Für den Zeitraffungsfaktor gilt:

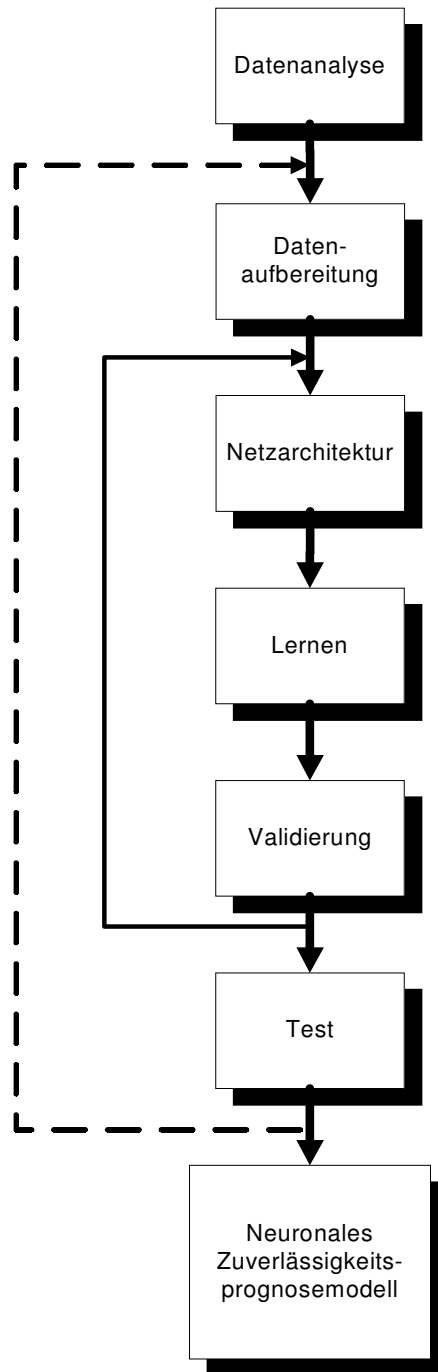
$$RF_{EY} = RF_{AR} \left( \frac{TK}{TK_0} \right)^m, \quad (6.10)$$

mit  $RF_{AR}$  als Raffungsfaktor des Arrhenius-Modells und  $0 < m < 1$  als eine Konstante.

Es existiert eine Vielzahl weiterer Zeitraffungs-Regressionsmodelle, auf die hier jedoch nicht weiter eingegangen wird. Einen ausführlichen Überblick zu den Modellen und deren Anwendung findet man u.a. in [Mee98].

## 6.2 Neuronaler Ansatz

Ziel ist es nun, ein Neuronales Netz zu erstellen, das es ermöglicht, die funktionalen Zusammenhänge zwischen dem Ausfallverhalten und möglicher Einflussgrößen zu modellieren. Mit ähnlicher Anwendung wurden Neuronale Netze in der Survival-Analysis, die sich mit der Analyse klinischer Daten beschäftigt, z.B. zur Prognose der Überlebenswahrscheinlichkeit von Krebs-Patienten, eingesetzt [Far95, Far97, Mar97, Big02]. Bei der Sicherheits- und Zuverlässigkeitsprognose sind die Neuronale Netze jedoch noch von geringerer Bedeutung. Ausnahmen hierzu sind [Lux95, Lux97, Liu95, Mah98]. Die methodische Vorgehensweise zur Entwicklung eines neuen Neuronalen Zuverlässigkeitsprognosemodells ist in Bild 6.1 dargestellt.



**Bild 6.1:** Entwicklungsschema Neuronales Zuverlässigkeitsprognosemodell

Ausgehend von den Garantiedaten und den Daten zur Beschreibung möglicher Einflussfaktoren sowie weiteren bekannten Informationen zum Ausfallverhalten, wird zunächst im Schritt „Datenanalyse“ nach typischen Ausfallmustern und Zusammenhängen zwischen dem Ausfallverhalten und möglichen Einflussgrößen gesucht.

Sind die für eine hinreichend genaue Modellierung notwendigen Einflussgrößen identifiziert, müssen die Daten für die Modellerstellung entsprechend aufbereitet werden (Schritt „Datenaufbereitung“). Für die unterschiedlich skalierten Einflussgrößen sind hierzu geeignete Kodierungen und Normierungen zu wählen. Ferner sind aus den vorhandenen Daten unabhängige Lern- und Validierungsdatensätze zu generieren, deren gleichmäßige Verteilung entscheidend für die Modellanpassung ist.

Anschließend muss im Schritt „Netzarchitektur“ die Struktur des Netzes, wie die Anzahl verdeckter Schichten oder die Anzahl verdeckter Neuronen, festgelegt werden. Das Lernverhalten wird außer durch die Datenaufbereitung und Netzarchitektur auch durch die Wahl des Lernverfahrens, der Initialisierung, d.h. die Vorgabe eines Startwertes für den Lernvorgang und der Wahl der Lernparameter des Lernverfahrens beeinflusst.

Um sicherzustellen, dass sich das Verfahren (Schritt „Lernen“) nicht in einem lokalen Optimum verfängt, sollte ein Lernverfahren eingesetzt werden, das kleine lokale Minima überwinden kann. Des Weiteren sollte nacheinander von unterschiedlichen Startwerten (Initialisierung) aus gestartet sowie mit unterschiedlichen Lernparametern gelernt werden.

Anhand des Validierungsergebnisses (u.a. Fehler des Validierungsdatensatzes) wird im Schritt „Validierung“ entschieden, ob durch ein zielgerichtetes Anpassen der vorhergehenden Schritte weitere Verbesserungen erreicht werden können. Bei Bedarf sind dabei nicht nur die Schritte „Netzarchitektur“ und „Lernen“ erneut zu durchlaufen, sondern auch die „Datenaufbereitung“ zu variieren.

Ist auf diese Weise ein geeignetes Modell für die Zuverlässigkeitsprognose erstellt, wird es im abschließenden Schritt mit Hilfe eines dem Netz bisher unbekanntes Datensatzes getestet (Schritt „Test“). Das Netz sollte dann in der Lage sein, das Ausfallverhalten für die Testdaten auf Basis der Lern- und Validierungsdaten zu prognostizieren.

Im Folgenden werden nun die wichtigsten Grundlagen zur Erstellung eines neuronalen Zuverlässigkeitsprognosemodells kurz erläutert.

### 6.2.1 Datentransformation

Die Effektivität Neuronaler Netze lässt sich häufig durch geeignete Transformationen bzw. Normierungen der Eingangs- und Ausgangsinformationen steigern. In Tabelle 6.1 sind einige praxisrelevante Ansätze dargestellt, wobei  $c$  jeweils einen konstanten Wert kennzeichnet. Eine ausführliche Darstellung zu Transformationen bei der Datenanalyse findet man u.a. in [Har98].


Tabelle 6.1: Auswahl praxisrelevanter Transformationen

Transformation	Formel
Wurzel-Transformation	$g(x) = \sqrt{x+c}$
Logarithmische Transformation	$g(x) = \ln(x+c)$
Box-Cox-Transformation	$g(x) = \begin{cases} \frac{(x+c)^\lambda - 1}{\lambda} & , \text{ falls } \lambda \neq 0 \\ \ln(x+c) & , \text{ falls } \lambda = 0. \end{cases}$
Reziproke Transformation	$g(x) = x^{-1}$
Arcus-Sinus Transformation	$g(x) = \sqrt{n+c_1} \cdot \arcsin \sqrt{\frac{x+c_2}{n+c_3}}$
Fischersche Z-Transformation	$g(x) = \arctan h(x)$
Logit-Transformation	$g(x) = \log \left[ \frac{x}{1-x} \right]$
Lineare Transformation	$g(x) = 2 \cdot \frac{x-x_{\min}}{x_{\max}-x_{\min}} - 1$
Standardisierung	$g(x) = \frac{x-\bar{x}}{\sigma_x}$

### 6.2.2 Netzarchitektur

Netzwerke mit vorwärtsgerichteter Struktur haben in der wissenschaftlichen Literatur die größte Bedeutung erlangt und werden, da sie bei einer Vielzahl von Problemen anwendbar sind, in der Praxis am häufigsten eingesetzt. Man bezeichnet diese Netze auch als Multi Layered Perceptron (MLP). Neben der vorwärtsgerichteten Struktur besteht das wesentliche Charakteristikum der MLP-Netzwerke darin, dass sie auf eine im Voraus bekannte Zielvariable, die zu erklärende Variable, hintrainiert werden (überwachtes Lernen). MLP-Netze sind in der Lage, jede beliebige Funktion bis zu einer gewünschten

Genauigkeit zu approximieren, vorausgesetzt, sie sind mit einer hinreichend großen Anzahl von verdeckten Neuronen ausgestattet. Im Vergleich zu den rein statistischen Ansätzen haben sie damit den Vorteil, dass im Vorfeld der Analyse keine Annahmen bezüglich der funktionalen Zusammenhänge gemacht werden müssen. Das folgende Bild 6.2 zeigt den prinzipiellen Aufbau eines MLP-Netzwerks mit einer verdeckten Schicht.



**Bild 6.2: Schematischer Aufbau eines MLP-Netzwerks**

Eine der häufigsten Anwendungen Neuronaler Netze in der Statistik ist die Erklärung oder Prognose bestimmter Variablen unter Verwendung von Beobachtungen anderer Variablen und externen Wissens.

Dabei versucht man mit Hilfe der neuronalen Netze die wahre Funktion  $F$ , die den tatsächlichen Zusammenhang zwischen exogenen und endogenen Variablen beschreibt, durch eine Funktion  $\hat{F}$  abzubilden, indem man die Parameter von  $\hat{F}$  bestimmt bzw. schätzt.

Die mittlere quadratische Abweichung (Mean Squared Error ( $MSE$ )) eines jeden Schätzers unterteilt sich dabei in Bias und Varianz. Es gilt:

$$MSE(\hat{\theta}) = Bias[\hat{\theta}]^2 + Var[\hat{\theta}]. \quad (6.11)$$

Der Bias stellt die Verzerrung des Schätzers dar und ist als Abweichung des Erwartungswerts des Schätzers von seinem tatsächlichen Wert definiert. Die Varianz des Schätzers entspricht der durchschnittlichen quadrierten Abweichung des Schätzers von seinem Erwartungswert.

Ein zu kleines neuronales Modell ist sehr unflexibel und nicht in der Lage, die wahre Funktion  $F$  nachzubilden und führt daher zu großen Abweichungen zwischen der Modellschätzung und der wahren Funktion. Es erzeugt folglich einen großen Bias. Ein zu großes Modell passt sich dagegen im Extremfall exakt an die beobachteten Daten an. Dadurch verschwindet zwar der Bias der Modellschätzung, diese enthält jedoch eine große Varianz, die der Varianz der Störterme entspricht. Das Problem von Bias und Varianz wird auch als „Bias-Varianz-Dilemma“ bezeichnet [Gem92].

Bei der Wahl einer bestimmten Netzwerkkomplexität wird daher immer ein Kompromiss zwischen Bias und Varianz eingegangen. Ein Netzwerk mit niedriger Komplexität liefert mit großer Wahrscheinlichkeit eine verzerrte Schätzung, da nur eine geringe Anzahl von Funktionen approximiert werden kann. Ein Netz mit großer Komplexität besitzt einen niedrigen Bias, leidet dafür jedoch an einer hohen Varianz des Modells. Ziel jedes Modellbildungsprozesses ist es, eine Architektur zu finden, die den besten Kompromiss zwischen Bias und Varianz des Modells eingeht.

Eine einfache Abschätzung der oberen Grenze der Neuronenzahl in der verdeckten Schicht  $n_{VN}$ , lässt sich anhand folgender Gleichung durchführen [Ott95], zitiert nach [Heu97]:

$$n_{VN} = \frac{n_{Train}}{5 \cdot (n_{EN} + n_{AN})}, \quad (6.12)$$

mit  $n_{Train}$ : Anzahl Trainingsdaten,  
 $n_{EN}$ : Anzahl Eingangsneuronen,  
 $n_{AN}$ : Anzahl Ausgangsneuronen.

Neuronale Netze besitzen eine starke Analogie zu statistischen Methoden. Nach [And97] können sie auch als eine neue Klasse von statistischen Verfahren aufgefasst werden. So lassen sich in Abhängigkeit der gewählten Aktivierungsfunktion mit Neuronalen Netze auch verschiedene Regressionsmodelle nachbilden. Verwendet man beispielsweise eine lineare Aktivierungsfunktion für die Neuronen, entspricht das MLP einer linearen Regression. Bei sigmoiden Aktivierungsfunktionen ergeben sich hingegen komplexe, nichtlineare Modelle. Die Terminologie des statistischen und neuronalen Ansatzes ist in der folgenden

Tabelle 6.2 gegenübergestellt.



Tabelle 6.2: Vergleich der Terminologie [And97]

Neuronaler Ansatz	Statistischer Ansatz
Netzwerkarchitektur	Modellspezifikation
Ungeeignete Netzwerkarchitektur	Über- bzw. Unterparametrisierung
Aktivierungsfunktion	Transformationsfunktion
Eingangsvariablen	Erklärende (unabhängige) Variablen
Zielvariablen	Zu erklärende (abhängige) Variablen
Gewichte	Parameter
Training	Parameterschätzung
Trainings-, Validierungsmenge	In-Sample Menge
Testmenge	Out-of-Sample Menge
Konvergenz	In-Sample Qualität
Generalisierung	Out-of-Sample Qualität

### 6.2.3 Lernverfahren

Eine besondere Stärke Neuronaler Netze ist es, Regelmäßigkeiten in Daten selbständig zu erkennen und zu erlernen. Im Rahmen dieser Arbeit soll auf das überwachte Lernen eingegangen werden. Bei dem so genannten Netztraining wird die Gewichtsmatrix des Neuronalen Netzes in der Weise modifiziert, dass sich der Testfehler des Netzes solange verbessert, bis ein Abbruchkriterium erfüllt ist. Als Maß für die Genauigkeit dient die Summe der quadratischen Abweichung  $SSE$  der vorgegebenen gewünschten Ausgabevektoren  $y_i$  und den durch das Netz bestimmten Vektoren  $\hat{y}_i$ :

$$SSE = \sum_{i=1}^q \left( \|\hat{y}_i - y_i\| \right)^2, \quad (6.13)$$

wobei  $q$  die Anzahl der Trainingsmuster bezeichnet.

Zur Minimierung des quadratischen Fehlers des Netzes existieren verschiedene Lernverfahren. Eines der bekanntesten und meist eingesetzten Lernverfahren ist die

Backpropagation-Methode (Fehlerrückführungs-Methode). Die Backpropagation ist ein Gradientenverfahren. Es soll hier lediglich ein Überblick über den Lernalgorithmus gegeben werden. Eine genaue Darstellung mit Herleitung findet sich in der entsprechenden Fachliteratur [Roj93, Zel00].

Bei der Backpropagation erfolgt die Änderung der Gewichte nach folgender Gleichung:

$$\Delta w_{ij} = \eta \delta_j e_i, \quad (6.14)$$

wobei  $\eta$  die Lernrate und  $\delta_j$  ein vom Neuron  $j$  abhängiges Fehlersignal ist. Handelt es sich bei dem Neuron  $j$  um ein Ausgabe-Neuron, so gilt:

$$\delta_j = \frac{\partial f}{\partial net_j} (y_j - \hat{y}_j) \quad (6.15)$$

und für verdeckte Neuronen

$$\delta_j = \frac{\partial f}{\partial net_j} \sum_k w_{kj} \delta_k, \quad \text{mit } net_j = \sum_i e_i w_{ij}. \quad (6.16)$$

Der Index  $k$  kennzeichnet hier alle Neuronen nachfolgender Schichten, die mit dem Neuron  $j$  verbunden sind. Im Falle verdeckter Neuronen wird die Abweichung zwischen gewünschter und tatsächlicher Ausgabe eines verdeckten Neurons  $j$  durch die gewichtete Summe der Terme  $\delta_k$  ersetzt. Ausgehend von der Ausgabeschicht des Netzes wird dann der Fehler Schicht für Schicht zurückgeführt und die Gewichte entsprechend angepasst.

Ein Problem dieses Verfahrens ist, dass die Minimierung entlang des steilsten Abstiegs oft in ein lokales Minimum führt, das weit vom globalen Minimum entfernt ist. Es kommt dann zu einer Stagnation des Algorithmus, da der Gradient gegen Null strebt. In Bereichen in denen die Fehlerfläche sehr flach ist, konvergiert der Algorithmus sehr langsam. In steilen Schluchten der Fehlerfläche tritt dagegen das Problem der Oszillation auf. Die Gewichtsänderungen sind in diesem Fall so groß, dass zwischen den Wänden der Fehlerschlucht hin und her gesprungen wird. Eine Möglichkeit diese Probleme zu überwinden, bietet die Erweiterung des Verfahrens um einen Momentum-Term. Dieses Verfahren wird auch als konjugierter Gradientenabstieg bezeichnet und wurde von Rumelhart, Hinton und Williams [Rum86] beschrieben. Die Methode beruht auf der Einführung eines Terms  $\pi \Delta w_{ij}$ , der die bereits vollzogene Gewichtsänderung zum Zeitpunkt  $t$  bei der Berechnung der Änderung zum Zeitpunkt  $t+1$  berücksichtigt. Es gilt dann:

$$\Delta w_{ij}(t+1) = \eta \delta_j e_i + \pi \Delta w_{ij}(t), \quad (6.17)$$

mit  $\pi$  als Momentum-Koeffizient. Der eingeführte Term bewirkt eine Beschleunigung bzw. Erhöhung der Gewichtsänderungen in Plateaus und eine Abbremsung in stark zerklüfteten Fehlerflächen.

Verwendet man bei der Berechnung der optimalen Gewichtsänderung auch die zweiten Ableitungen, so kommt man zu den Backpropagation-Verfahren zweiter Ordnung, wie das Quickpropagation, kurz Quickprop-Verfahren, von Fahlman [Fah88]. Weitere dem Backpropagation verwandte Lernverfahren sind Weight Decay und Rprop. Auf diese Verfahren wird im Rahmen dieser Arbeit jedoch nicht weiter eingegangen. Eine ausführliche Darstellung findet man u.a. in [Zel00].

Beim Training eines Neuronalen Netzes wird der Netzfehler für den Trainings- wie auch den Validierungsdatensatz berechnet. Ein Netz gilt als optimal trainiert, wenn der Validierungsdatensatz einen möglichst kleinen Fehler aufweist. Man versucht daher, das Netztraining in einem Fehlerminimum des Validierungsdatensatzes zu stoppen. Wird das Netz dennoch weiter trainiert, nimmt die Generalisierungsfähigkeit stark ab. Das Netz lernt dann nur noch den Trainingsdatensatz auswendig und erkennt nicht mehr die funktionalen Zusammenhänge zwischen den Eingangs- und Ausgangsgrößen.

#### 6.2.4 Gütemaße

Zur Beurteilung der Güte eines Neuronalen Netzwerks existieren verschiedene Fehlerkriterien. Durch die Fehlermaße können verschiedene Modelle miteinander verglichen und damit eine optimale Struktur für die gewünschte Aufgabe gefunden werden. Eine Auswahl von Gütemaßen ist in Tabelle 6.3 dargestellt. Der Wert  $k$  kennzeichnet dabei die Anzahl der angelegten Datensätze bzw. Datenmuster.

Tabelle 6.3: Übersicht von Fehler- bzw. Gütemaßen

Fehler-, Gütemaß	Formel
Summe der quadratischen Fehler ( <i>SSE</i> )	$SSE = \sum_{i=1}^k (\hat{y}_i - y_i)^2$
Mittlerer quadratischer Fehler ( <i>MSE</i> )	$MSE = \frac{\sum_{i=1}^k (\hat{y}_i - y_i)^2}{k}$
Wurzel des mittleren quadratischen Fehlers ( <i>RMSE</i> )	$RMSE = \sqrt{\frac{\sum_{i=1}^k (\hat{y}_i - y_i)^2}{k}}$
Multipler Determinationskoeffizient ( $R^2$ )	$R^2 = 1 - \frac{\sum_{i=1}^k (\hat{y}_i - y_i)^2}{\sum_{i=1}^k (\hat{y}_i - \bar{y})^2}$

Bei der Berechnung der Gütemaße ist es unter Umständen sinnvoll, zusätzlich die Anzahl der Verbindungen bzw. Gewichte sowie die Anzahl der Ausgabeneuronen zu berücksichtigen. Ansätze hierzu findet man u.a. in [Zel99].

## 6.3 Verwendete Daten

### 6.3.1 Klimadaten

Der nordamerikanische Kontinent hat Anteil an allen Klimazonen, wobei die polaren Regionen nur im Norden Alaskas und die tropischen Regionen nur im Süden Floridas gestreift werden. Der größte Teil der USA liegt in der kühlgemäßigten Zone, an die sich südwärts des 40. Breitengrades eine warmgemäßigte Subtropenzone anschließt. Beide Klimagürtel erstrecken sich von Ost nach West über den gesamten Kontinent. Die Grenze zwischen dem ariden Westteil und dem humiden Ostteil verläuft am 98. Längengrad. Durch den meridonalen Verlauf der Gebirge kommt es zu einer starken Differenzierung des Klimas Nordamerikas. Ozeanische Einflüsse werden durch die Kordilleren weitgehend vom Landesinnern abgeriegelt, so dass kontinentale Klimamerkmale bei Weitem überwiegen. Der Stau effekt der Gebirge hat zur Folge, dass die pazifische Küs-

te reichlich Niederschläge empfängt, die östlich gelegenen Gebiete jedoch außerordentlich niederschlagsarm sind und daher Wüsten- und Halbwüstencharakter besitzen. Ähnliche Effekte treten auch in den östlich der Rocky Mountains gelegenen Great Plains auf. Von der Mitte des Staatsgebiets nimmt die Humidität nach Osten zu. Durch die meridonalen Gebirgsketten kommt es zu weitem Vordringen arktischer Luftmassen südwärts und tropischer Luftmassen nordwärts, was zu schroffen Wetterwechseln und schnellen Temperaturänderungen führt [nach Blu87].

Zur Beschreibung der klimatischen Verhältnisse wurden verschiedene nationale und internationale Datenbanken mit klimatologischen Daten ausgewertet [NOA02]. Die Klimadaten geben die durchschnittlichen Werte des jeweiligen US-Bundesstaates wieder. Es wurden folgende klimatische Daten ermittelt:

- monatliche Niederschlagsmenge,
- jahreszeitliche Niederschlagsmenge,
- jährliche Niederschlagsmenge,
- monatliche Durchschnittstemperatur,
- jahreszeitliche Durchschnittstemperatur,
- jährliche Durchschnittstemperatur,
- monatliche Regentage mit mehr als 0,254 mm ( $\cong$  0,01 Inch) Niederschlag,
- jährliche Regentage mit mehr als 0,254 mm ( $\cong$  0,01 Inch) Niederschlag.

Ergänzend wurden auch die Bevölkerungszahlen und die zugehörigen Flächen der US-Bundesstaaten ermittelt.

### 6.3.2 Garantiedaten

Die praktische Untersuchung des Ausfallverhaltens unter Berücksichtigung von zusätzlichen Einflussgrößen wird für Wischermotoren eines Mittelklassewagens durchgeführt. Für die Untersuchung stehen Garantiedaten aus einer 2-jährigen Garantiezeit aus den USA zur Verfügung. Die Daten enthalten alle, in Kapitel 4 geforderten Informationen bezüglich der Ausfälle des betrachteten Systems. Des Weiteren enthalten sie auch die Angaben des jeweiligen US-Bundesstaates, in dem die Fahrzeuge zugelassen waren. Für die folgenden Untersuchungen wird die Annahme getroffen, dass die Mehrzahl der Fahrzeuge vorwiegend in den Bundesstaaten der Zulassung oder den benachbarten Staaten gefahren sind. Auf Grund dieser Annahme kann eine geographische Zuordnung der Garantiefälle erfolgen.

Bei der Analyse werden nur solche Staaten berücksichtigt, die eine ausreichende absolute Anzahl von Ausfällen für eine gesicherte statistische Auswertung aufweisen. Diese Staaten sind in der folgenden Graphik hervorgehoben (Bild 6.3). Von einer Zusammenlegung der Ausfälle benachbarter Staaten wird abgesehen, da keine gesicherten Erkenntnisse über die relevanten Einflussfaktoren vorliegen und daher eine Einteilung in homogene Regionen nur bedingt möglich ist.

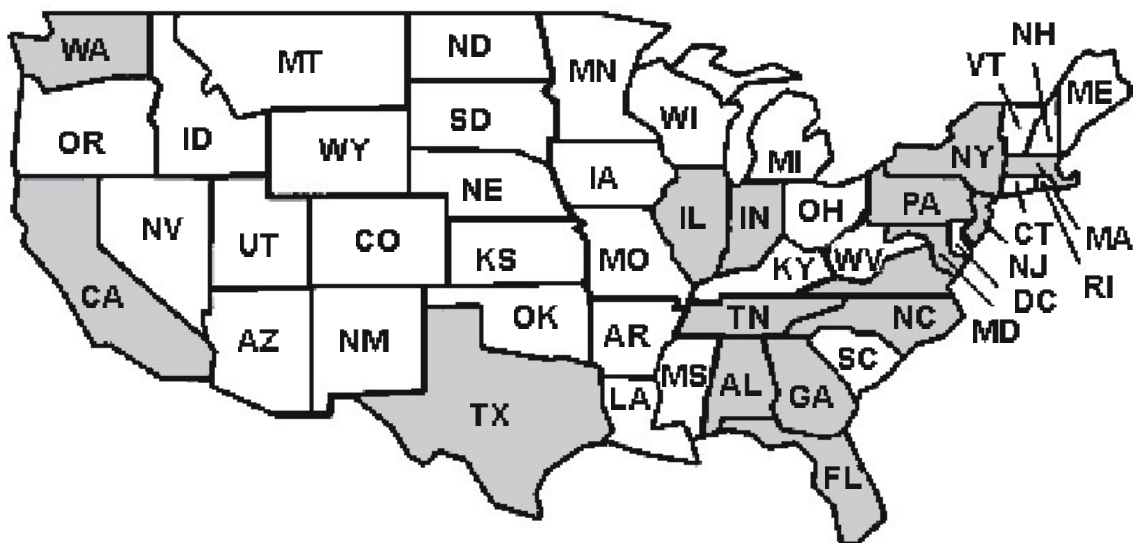


Bild 6.3: Ausgewählte US-Bundesstaaten

In Bild 6.3 lässt sich erkennen, dass vorwiegend Staaten im Osten der USA und in Küstenregionen eine ausreichende Anzahl von Ausfällen aufweisen. Dies kann zum einen durch die höheren Bevölkerungsdichten und damit einer höheren Anzahl von Fahrzeugen und zum anderen durch die stärkeren Niederschläge in diesen Gebieten begründet werden.

## 6.4 Ermittelte Einflussgrößen

Bei ersten Voruntersuchungen zeigten sich deutliche Unterschiede bei dem Ausfallverhalten der Wischermotoren in den ausgewählten US-Bundesstaaten. Grund hierfür sind verschiedene externe Einflussfaktoren, deren funktionale Wirkungsweise jedoch unbekannt ist. Ein Ziel ist es, solche möglichen Einflussfaktoren zu identifizieren und entsprechend für das neuronale Modell aufzubereiten. Da bei den Wischermotoren davon auszugehen ist, dass deren Ausfallverhalten im Wesentlichen von klimatischen Faktoren beeinflusst wird, werden auf Basis der ermittelten Klimadaten, die in Tabelle 6.4 dargestellten Parameter für die Analyse angenommen. Als zusätzliche Einflussgröße wird

auch die Bevölkerungsdichte definiert. Diese dient als Maß für die Urbanisierung eines Bundesstaates. Sie soll dem Neuronalen Netz ermöglichen hierzu korrelierende Größen mit zu berücksichtigen.

Die nach Jahreszeiten unterschiedenen monatlichen Niederschlagsmengen charakterisieren die Niederschlagsverteilung über das Jahr. Die jährliche Niederschlagsmenge beschreibt das absolute Niederschlagsaufkommen in einem Bundesstaat. Zur Modellierung jahreszeitlicher Schwankungen wird des Weiteren die maximale Differenz zwischen den jahreszeitlich unterschiedenen monatlichen Niederschlagsmengen verwendet.

**Tabelle 6.4: Ausgewählte Einflussfaktoren**

<b>BD</b>	Bevölkerungsdichte [Einwohner/qkm]
<b>NW</b>	Monatliche Niederschlagsmenge im Winter (Dez.-Feb.) [mm]
<b>NF</b>	Monatliche Niederschlagsmenge im Frühling (Mrz.-Mai) [mm]
<b>NS</b>	Monatliche Niederschlagsmenge im Sommer (Jun.-Aug.) [mm]
<b>NH</b>	Monatliche Niederschlagsmenge im Herbst (Sep.-Nov.) [mm]
<b>NJ</b>	Jahresniederschlagsmenge [mm]
<b>DN</b>	Maximale Differenz monatlicher Niederschläge zwischen Jahreszeiten [mm]
<b>TJ</b>	Jährliche Durchschnittstemperatur [°C]
<b>RT</b>	Regentage pro Jahr mit mehr als 0,254 mm Niederschlag
<b>DR</b>	Maximale Differenz monatlicher Regentage mit mehr als 0,254 mm Niederschlag

Um das Temperaturniveau bei der Modellbildung berücksichtigen zu können, wird als weitere Einflussgröße die Jahresdurchschnittstemperatur des jeweiligen US-Bundesstaates eingesetzt.

Die Regenwahrscheinlichkeit wird durch die Anzahl der Regentage mit mehr als 0,254 mm Niederschlag charakterisiert. So ist es möglich zu unterscheiden, ob die Niederschläge nur an wenigen Tagen, oder gleichmäßig verteilt fallen. Durch die maximale Differenz der monatlichen Regentage können auch jahreszeitliche Schwankungen erfasst und modelliert werden.

## 6.5 Entwicklung eines neuronalen Zuverlässigkeitsprognosemodells

Die genaue Wirkungsweise der Einflussgrößen auf das Ausfallverhalten der Wischermotoren ist weitestgehend unbekannt. Es existieren jedoch möglicherweise komplexe nichtlineare Zusammenhänge zwischen den Einflussgrößen und dem Ausfallverhalten der Motoren. Bei rein statistischen Ansätzen müssen vorab Annahmen über das zu verwendende Regressionsmodell getroffen werden. Wählt man dagegen einen neuronalen Ansatz, sind keine Annahmen oder Einschränkungen bei der Modellierung notwendig.

### 6.5.1 Datenanalyse und Datenaufbereitung

Auf Basis der definierten Einflussfaktoren und der ermittelten Klimadaten für die US-Bundesstaaten wurden die in Tabelle 6.5 aufgetragenen Parameter für die Modellbildung ermittelt.

Zusätzlich zu den bestimmten Einflussfaktoren ist es notwendig, das Ausfallverhalten der Wischermotoren innerhalb eines Staates zu beschreiben, hierzu eignet sich besonders ein Teilpopulation-Ausfallmodell. Die in den Garantiedaten enthaltenen Informationen zu den Fehlerursachen und Fehlermechanismen unterstützen die Annahme eines solchen Modells. Als Verteilungsmodell wurde für alle Staaten eine Weibull-Verteilung verwendet. Die Ergebnisse der Parameterschätzungen sind ebenfalls in Tabelle 6.5 eingetragen, wobei  $W-\beta$  den geschätzten Parameter  $\beta$  und  $W-T^*$  die geschätzte charakteristische Lebensdauer  $T^*$  der Weibull-Verteilung kennzeichnet.




Tabelle 6.5: Parameter der Eingangsgrößen für die ausgewählten US-Bundesstaaten

Staat	W- $\beta$	W-T <sup>*</sup> [tkm]	BD [E/qkm]	NW [mm]	NF [mm]	NS [mm]	NH [mm]	NJ [mm]	DN [mm]	TJ [°C]	RT [d]	DR [d]
Alabama	1,41	20,334	33,27	136,4	136,4	117,35	103,38	1480,06	33,02	17,11	116,2	5,8
California	1,108	16,258	82,41	96,27	49,02	6,86	37,34	563,37	89,41	15,22	56,6	7,57
Florida	1,587	13,224	105,38	80,52	92,2	181,1	107,7	1384,81	100,58	21,5	116,2	9,54
Georgia	1,41	15,462	53,69	115,57	105,66	119,63	88,14	1286,76	31,49	17,5	110,3	6,17
Illinois	1,069	13,557	85,02	56,39	96,27	99,57	80,01	996,44	43,18	11	116,2	3,67
Indiana	1,132	14,38	64,69	65,79	100,08	104,39	82,55	1059,69	38,6	10,94	129,3	4,75
Massachusetts	1,315	10,982	296,89	97,28	103,12	98,81	104,39	1211,07	7,11	8,83	131	3
Maryland	1,013	14,304	214,2	85,6	99,82	100,84	90,932	1131,32	15,24	12,33	114	4
North Carolina	1,394	14,69	58,96	99,57	105,16	121,92	99,57	1278,65	22,35	15	117	4,33
New Jersey	1,152	8,586	414,6	89,66	104,9	108,46	95,5	1195,83	18,8	11,5	114,7	3,33
New York	1,569	9,354	147,79	72,9	86,61	98,81	95,5	1061,72	25,91	7,44	141,1	4,78
Pennsylvania	1,263	9,33	104,6	73,91	93,22	104,9	90,93	1088,9	30,99	9,33	135,1	3,38
Tennessee	1,918	11,605	52	119,89	130,81	107,19	101,98	1376,17	28,83	14,22	121,3	5
Texas	1,468	12,366	30,11	42,93	63,5	68,83	68,83	733,552	25,9	18,22	75,7	1,72
Virginia	1,729	9,133	66,96	83,82	99,31	101,35	90,932	1125,22	17,53	12,83	115,8	4
Washington	1,656	7,721	33,37	132,58	73,66	32,512	87,884	976,376	100,07	9,06	138,3	11,43

### 6.5.2 Netzarchitektur

Für das neuronale Zuverlässigkeitsprognosemodell wird ein Multi Layered Perceptron-Netzwerk verwendet, da sich dieses, wie bereits erwähnt, besonders gut zur Approximation funktionaler Zusammenhänge zwischen abhängigen und erklärenden Variablen eignet. Bild 6.4 zeigt den prinzipiellen Aufbau des Netzwerks. Der Aufbau der verdeckten Neuronenschicht ist nicht genau angegeben, da dieser im Laufe der Netzwerkoptimierung noch zu spezifizieren ist. Die Eingangsgrößen setzen sich aus den zuvor ausgewählten Einflussgrößen und der Fahrstrecke  $s$  zusammen. Die Ausgangsgröße beschreibt die km-abhängige Ausfallwahrscheinlichkeit  $F(s)$  für jede Strecke  $s$  in Abhängigkeit der den US-Bundesstaat charakterisierenden Einflussgrößen.



**Bild 6.4: Grundstruktur des verwendeten MLP-Netzwerks**

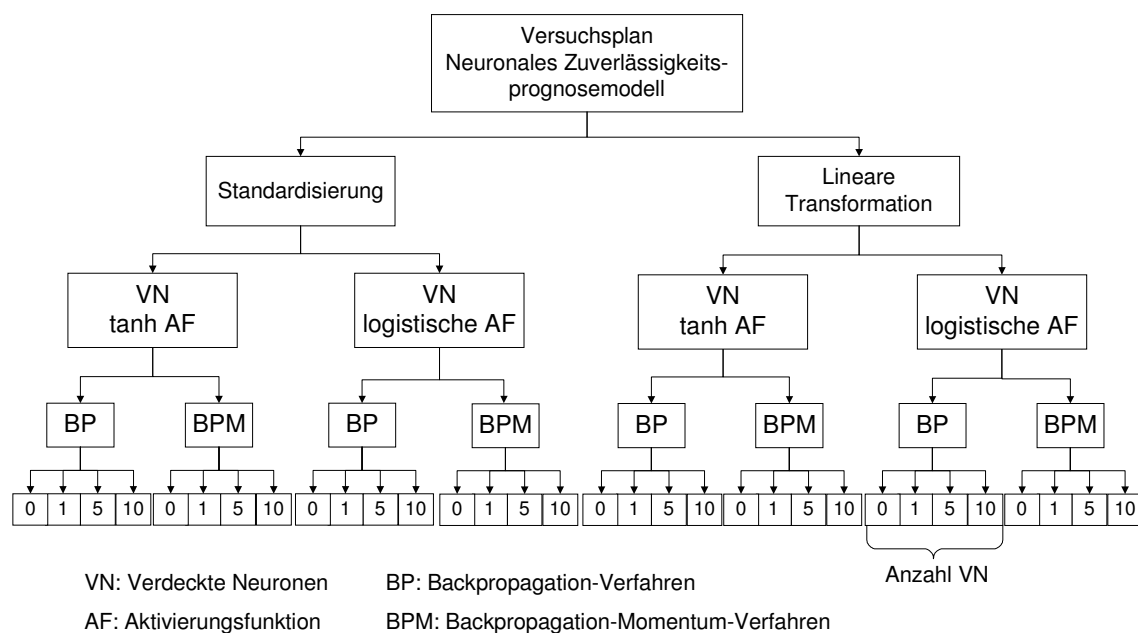
Um dem Neuronalen Netz das km-abhängige Ausfallverhalten der Wischermotoren präsentieren zu können, ist es notwendig, den Verlauf der km-abhängigen Ausfallwahrscheinlichkeit geeignet zu kodieren. Dazu wird die Ausfallwahrscheinlichkeit für verschiedene diskrete Strecken  $s_i$ , mit  $i = 1, 2, \dots, n$ , bestimmt. Bild 6.5 zeigt beispielhaft die für Florida ermittelte km-abhängige Ausfallwahrscheinlichkeit für diskrete Werte der gefahrenen Strecke  $s_i$ .



Das Netz soll nach dem Lernvorgang in der Lage sein, die zu jedem  $s_i$  gehörende Ausfallwahrscheinlichkeit  $F(s_i)$  ausreichend gut zu approximieren, so dass der Fehler zwischen den Sollwerten der Netzausgabe und den Istwerten minimal ist.

### 6.5.3 Versuchsplan

Das Auffinden eines optimalen Neuronalen Netzes ist ein rein iterativer Vorgang nach dem „Trial and Error“-Verfahren. Um dennoch eine systematische Vorgehensweise sicherzustellen und möglichst viele Faktoren und deren Einflüsse auf die Güte des Neuronalen Modells zu analysieren, wurde ein entsprechender Versuchsplan entwickelt. So werden zur systematischen Ermittlung eines optimalen neuronalen Modells verschiedene Transformationen der Eingangsgrößen verwendet. Des Weiteren werden die Aktivierungsfunktionen der verdeckten Neuronen variiert und unterschiedliche Lernverfahren eingesetzt. Die Anzahl der verdeckten Neuronen wird ebenfalls für jedes Netz variiert. Das im Folgenden dargestellte Schema (Bild 6 .6) zeigt den entwickelten Versuchsplan zur Bestimmung eines geeigneten Neuronalen Netzes.



**Bild 6 .6: Entwickelter Versuchsplan zur Ermittlung eines optimalen neuronalen Modells**

Bei der Datenvorverarbeitung werden die Daten zum einen standardisiert und zum anderen in das Intervall  $[0,2;0,8]$  linear transformiert. Eine allgemeine Beschreibung der Datentransformationen befindet sich in Kapitel 6.2.1. Des Weiteren werden neuronale Modelle sowohl mit logistischer Aktivierungsfunktion, als auch mit der tanh-Funktion

als Aktivierungsfunktion entwickelt. Diese sigmoiden Aktivierungsfunktionen zählen zu den meist verwendeten Aktivierungsfunktionen bei der neuronalen Modellbildung [War96]. Als Lernverfahren dient das Backpropagation-Verfahren und das, mit einem Momentum-Term erweiterte, Backpropagation-Verfahren. Es werden im Rahmen der Untersuchungen Neuronale Netze mit keinem, einem, fünf und zehn verdeckten Neuronen analysiert. Des Weiteren werden verschiedene Trainings-, Validierungs- und Testdatensätze aus den Garantiedaten erstellt. Die Zusammensetzung der Datensätze ist in Tabelle 6.7 veranschaulicht. Mit Hilfe des entwickelten Versuchplans soll systematisch ein zur Approximation der funktionalen Zusammenhänge geeignetes Neuronales Netz gefunden werden.

**Tabelle 6.7: Einteilung der Trainings-, Validierungs- und Testdaten (US-Bundesstaaten)**


Datensatz	Trainingsdaten	Validierungsdaten	Testdaten
I	AL, CA, FL, IL, IN, NJ, MA, NY, TN, TX, WA	MD, PA, VA	NC, GA
II	AL, CA, FL, IN, MA, NY, TN, TX	GA, MD, PA, VA	IL, NC, NJ, WA

## 6.6 Ergebnisse

Für die Transformation der Daten wurden eigene Programme mit der Entwicklungsoftware Mathematica™ Version 4.0 geschrieben. Alle entwickelten Neuronale Netze wurden mit Hilfe des Stuttgarter Neuronale Netze Simulators (SNNS) modelliert und entsprechend simuliert. Die Auswertung und weitere Verarbeitung der gewonnenen Ergebnisse erfolgte ebenfalls mit eigenen Programmen in Mathematica™.

Wie bereits erwähnt, spielt die Anzahl der Neuronen in der verdeckten Schicht eine wichtige Rolle bei der neuronalen Modellbildung. Je mehr verdeckte Neuronen verwendet werden, desto exakter lässt sich eine Approximation der gesuchten Funktion erreichen. Bild 6.7 zeigt den Verlauf des Netzfehlers in Abhängigkeit der Trainingszyklen für eine verschiedene Anzahl verdeckter Neuronen. Als Gütemaß dient hierbei die Summe der Abweichungsquadrate ( $SSE$ ). Es lässt sich erkennen, dass mit zunehmender Anzahl verdeckter Neuronen der Netzfehler abnimmt. Wählt man jedoch die Zahl der verdeckten Neuronen zu groß, steigt die Varianz des Netzes an. Es ist daher bei der Er-

stellung eines geeigneten Neuronalen Netzes darauf zu achten, dass die Zahl verdeckter Neuronen so gering wie möglich gewählt wird.



**Bild 6.7: Netzwerkfehler in Abhängigkeit der Anzahl verdeckter Neuronen**

Ziel ist es, ein geeignetes Neuronales Netz zu entwickeln, das die funktionalen Zusammenhänge zwischen den Einflussgrößen und der Ausfallwahrscheinlichkeit ausreichend gut beschreibt. Hierzu werden für die beiden Datensätze I und II entsprechend dem entwickelten Versuchplan Neuronale Netze entwickelt und anhand verschiedener Gütemaße bewertet. Besonders gut eignet sich hierzu der multiple Determinationskoeffizient  $R^2$ . Es gilt hierbei, je größer  $R^2$  ist, desto besser beschreibt das Neuronale Netz den anliegenden Datensatz. In Tabelle 6.8 und Tabelle 6.9 sind die entsprechenden Werte für alle entwickelten Netze aufgetragen. Eine ausführliche Darstellung der Ergebnisse mit dem jeweiligen Trainingsverlauf aller entwickelter Netze befindet sich im Anhang dieser Arbeit.

Tabelle 6.8: Multipler Determinationskoeffizient für den Versuchsplan (Datensatz I)

			$R^2$			
			Anz. VN	Trainings- daten	Validie- rungsdaten	Testdaten
Standardisie- rung	VN tanh AF	BP	0	0,8748	0,7114	0,8265
			1	0,9548	0,8471	0,8812
			5	0,997	0,9347	0,6283
			10	0,9826	0,8796	0,8741
	AF	BPM	0	0,8424	0,7561	0,8466
			1	0,9466	0,7681	0,798
			5	0,9875	0,8906	0,9095
			10	0,9833	0,8466	0,8965
	AF	BP	0	0,8748	0,7114	0,8265
			1	0,9453	0,7613	0,842
			5	0,9947	0,8816	0,7874
			10	0,9934	0,9219	0,8933
BPM		0	0,8424	0,7561	0,8466	
		1	0,9387	0,7609	0,78777	
		5	0,9941	0,9174	0,8566	
		10	0,9909	0,9191	0,8589	
Lineare Transformation	VN tanh AF	BP	0	0,8783	0,6747	0,8218
			1	0,9581	0,7855	0,8598
			5	0,9756	0,8868	0,9881
		10	0,9788	0,9011	0,9823	
		BPM	0	0,8795	0,6302	0,8227
			1	0,9583	0,7344	0,8409
	5		0,9759	0,8893	0,9851	
	AF	BP	0	0,8783	0,6747	0,8218
			1	0,9549	0,8611	0,9368
			5	0,975	0,8856	0,9617
			10	0,977	0,8866	0,9593
		BPM	0	0,8795	0,6302	0,8227
			1	0,957	0,8123	0,88
			5	0,9709	0,8499	0,9345
			10	0,9737	0,8698	0,9577


Tabelle 6.9: Multipler Determinationskoeffizient für den Versuchsplan (Datensatz II)

			$R^2$			
			Anz. VN	Trainings- daten	Validie- rungsdaten	Testdaten
<b>Standardisie- rung</b>	<b>VN tanh AF</b>	<b>BP</b>	<b>0</b>	0,8803	0,6907	0,6717
			<b>1</b>	0,9224	0,6621	0,7558
			<b>5</b>	0,9952	0,8934	0,7465
			<b>10</b>	0,9937	0,9557	0,8532
		<b>BPM</b>	<b>0</b>	0,8872	0,6574	0,6235
			<b>1</b>	0,8790	0,7220	0,7642
			<b>5</b>	0,9932	0,8883	0,8809
			<b>10</b>	0,9952	0,8937	0,9345
	<b>VN logisti- sche AF</b>	<b>BP</b>	<b>0</b>	0,8803	0,6907	0,6717
			<b>1</b>	0,8991	0,7754	0,7609
			<b>5</b>	0,9906	0,8637	0,9380
			<b>10</b>	0,9933	0,9659	0,7470
		<b>BPM</b>	<b>0</b>	0,8872	0,6574	0,6235
			<b>1</b>	0,9098	0,7738	0,7605
			<b>5</b>	0,9916	0,8849	0,9187
			<b>10</b>	0,9933	0,9550	0,7803
<b>Lineare Transformation</b>	<b>VN tanh AF</b>	<b>BP</b>	<b>0</b>	0,8932	0,7871	0,7800
			<b>1</b>	0,9562	0,9357	0,9170
			<b>5</b>	0,9678	0,9209	0,8428
			<b>10</b>	0,9702	0,9314	0,8609
		<b>BPM</b>	<b>0</b>	0,8789	0,7242	0,7471
			<b>1</b>	0,9574	0,9293	0,9121
			<b>5</b>	0,9714	0,9348	0,8620
			<b>10</b>	0,9651	0,9429	0,8843
	<b>VN logisti- sche AF</b>	<b>BP</b>	<b>0</b>	0,8932	0,7871	0,7800
			<b>1</b>	0,9557	0,9379	0,9157
			<b>5</b>	0,9663	0,9182	0,8457
			<b>10</b>	0,9678	0,9386	0,8677
		<b>BPM</b>	<b>0</b>	0,8789	0,7242	0,7471
			<b>1</b>	0,9562	0,9122	0,8988
			<b>5</b>	0,9703	0,9256	0,8604
			<b>10</b>	0,9653	0,9392	0,8814




Für alle Varianten lässt sich erkennen, dass mit zunehmender Anzahl von verdeckten Neuronen  $R^2$  für den Trainingsdatensatz zunimmt. Verwendet man keine verdeckten Neuronen, liefern alle Modelle schlechtere Ergebnisse. Ein solches Neuronales Netz mit nur einer Eingangs- und einer Ausgangsschicht entspricht, wie bereits erwähnt, der linearen Regression bei rein statistischen Ansätzen. Mit zunehmender Anzahl verdeckter Neuronen nimmt bei allen Modellen die Güte der Anpassung zu. Bei der Modellentwicklung hat sich jedoch auch gezeigt, dass bei größeren verdeckten Schichten die Varianz ebenfalls stark zunimmt. Dies zeigt sich beispielsweise darin, dass in manchen Fällen der Validierungs- und in anderen Fällen der Testdatensatz besser beschrieben wird. Das Netzverhalten deutet damit auf ein „overfitting“ mit einer geringen Generalisierungsfähigkeit hin. Bei den untersuchten Datensätze zeigt sich des Weiteren, dass die lineare Transformation der Daten meist bessere Ergebnissen liefert. Dagegen zeigen sich durch Variation der Aktivierungsfunktionen und des Lernverfahrens kaum Unterschiede. Bei der Standardisierung der Datensätze lassen sich allgemein jedoch bessere Anpassungen des Trainingsdatensatzes erreichen, wobei die Generalisierungsfähigkeit des Netzes jedoch mit Zunahme der verdeckten Neuronen abnimmt.

Auf Grundlage der aus den Versuchen gewonnenen Ergebnisse und den daraus abgeleiteten Erkenntnissen, wird nun eine optimiertes Neuronales Netz für das Neuronale Zuverlässigkeitsprognosemodell erstellt. Das gewählte Multi Layered Perceptron besitzt eine verdeckte Schicht mit vier verdeckten Neuronen (Bild 6.8).



**Bild 6.8: MLP des Neuronalen Zuverlässigkeitsprognosemodells**

Die Daten werden mit Hilfe der linearen Transformation entsprechend vorverarbeitet. Als Lernverfahren wird der Backpropagation-Algorithmus mit einer Lernrate  $\eta = 1,0$  verwendet. Bild 6.9 zeigt den Verlauf des Netzfehlers (SSE) für den Trainings- und Validierungsdatensatz. Bei etwa 5000 Lernzyklen wurde das Training des Netzes abgebrochen, da bei weiterem Training die Generalisierungsfähigkeit des Netzes stark abnehmen würde.



**Bild 6.9: Summe der Abweichungsquadrate (SSE) für Trainings- und Validierungsdaten**

Das trainierte Neuronale Netz ist nun in der Lage, die Ausfallwahrscheinlichkeit der untersuchten Wischermotoren in Abhängigkeit der definierten Einflussfaktoren zu approximieren und auf dem Netz unbekannte Daten zu übertragen. Zur Überprüfung werden dem Netz die Eingangsdaten des Testdatensatzes präsentiert. Das trainierte Netz bestimmt dann für den unbekanntes Datensatz die zugehörigen Ausgangsgrößen. Es prognostiziert somit die Ausfallwahrscheinlichkeit der Wischermotoren in anderen U.S.-Bundesstaaten unter Berücksichtigung der Einflussgrößen in diesen Staaten.

Die tatsächlichen und prognostizierten Ausfallwahrscheinlichkeiten für die US-Bundesstaaten Georgia und North Carolina der Testdaten (Datensatz I) sind in Bild 6.10 und Bild 6.11 dargestellt. Beide Bilder zeigen eine sehr gute Prognosegüte für die verwendeten Daten.

## GEORGIA -GA-




Bild 6.10: Tatsächliche und prognostizierte Ausfallwahrscheinlichkeit in Georgia

## NORTH CAROLINA -NC-




Bild 6.11: Tatsächliche und prognostizierte Ausfallwahrscheinlichkeit in North Carolina

Das trainierte Neuronale Netz bildet die Grundlage des neuronalen Zuverlässigkeitsprognosemodells, das in der Lage ist, das Ausfallverhalten der Wischermotoren auch bei dem Netz zuvor unbekanntem Einflussfaktoren zu prognostizieren.

Die beschriebene allgemeine Vorgehensweise zur Entwicklung solcher neuronalen Modelle lässt sich auch auf andere Anwendungsgebiete und Fragestellungen übertragen. So ist es beispielsweise oft schwierig, die Einflüsse der Testparameter bei gerafften Lebensdauertest zu modellieren oder komplexe Zusammenhänge bei kombinierten Prüfungen funktional zu beschreiben.

Die Neuronalen Netze stellen, wie am Beispiel der untersuchten Wischermotoren gezeigt, eine gute Ergänzung zu klassischen statistischen Methoden dar und lassen sich durch die flexible Modellierbarkeit auch gut in der betrieblichen Praxis einsetzen.

## 7 Zusammenfassung und Ausblick

Heutige und zukünftige Systeme im Kraftfahrzeug zeichnen sich durch eine hohe Komplexität und starke Vernetzung aus, wobei der Anteil elektronischer und elektromechanischer Baugruppen zur Realisierung immer neuer Funktionen stetig zunimmt. Dieser Trend wird sich auch in Zukunft fortsetzen und beschleunigen. So werden Komfort- und Assistenzsysteme aus Fahrzeugen der Oberklasse auch in Mittelklasse- und möglicherweise Kleinwagen eingebaut werden. Die Stückzahlen elektronischer Systeme werden entsprechend ansteigen und damit deren Feldverhalten verstärkt wahrgenommen werden. Dies führt zu einer zunehmenden Bedeutung der Qualität und Zuverlässigkeit solcher Systeme. Auf Grund dieser Entwicklungen wird es immer wichtiger, frühzeitig sicherheits- und zuverlässigkeitstechnische Betrachtungen durchzuführen. Zur Abschätzung der Risiken und zur Gewährleistung der Sicherheit von Produkten ist es notwendig, quantitative Aussagen über die zeitvarianten Auftretenswahrscheinlichkeiten unerwünschter Ereignisse zu machen. Grundlage hierfür ist es, das reale Feldverhalten gleicher oder ähnlicher Systeme zu analysieren und die gewonnenen Ergebnisse über einen Sicherheits- und Zuverlässigkeitsprozess in die Entwicklung neuer Produkte einfließen zu lassen.

Garantiedaten sind häufig die einzigen zur Verfügung stehenden Informationen über das tatsächliche Ausfallverhalten von Produkten im Feld. Es gilt daher Methoden und Modelle zu entwickeln, mit denen das vorhandene Wissen nutzbar gemacht und wertschöpfend in betriebliche Abläufe eingebracht werden kann.

In dieser Arbeit werden neue praxisgerechte Modelle entwickelt, die eine frühzeitige Prognose der Zuverlässigkeit von Komponenten, Baugruppen und komplexer Systeme auf Basis von Garantiedaten ermöglichen. Zur Beschreibung beliebiger Fehlermechanismen und Ausfallarten wird ein allgemeines Ausfallmodell entwickelt und in ein Zuverlässigkeitsprognosemodell integriert. Dieses neue allgemeine Zuverlässigkeitsprognosemodell erlaubt es, beliebige Systeme mit beliebigem Ausfallverhalten zu bewerten. So kann nun der gesamte Verlauf der Ausfallrate, die sogenannte Badewannenkurve, eines Systems beschrieben und entsprechend analysiert werden. Das entwickelte Modell wurde für verschiedene ausgewählte Produkte eines großen Automobilzulieferers angewendet und konnte so seine praxisgerechte Verwendbarkeit belegen. Mit Hilfe der gewonnenen Ergebnisse können des Weiteren zusätzliche Kenngrößen, wie die zu erwartenden Kosten einer Garantiezeitverlängerung, der Serienersatzbedarf und die etwaigen Endbevorratungsmengen geschätzt werden. Außerdem kann durch die Analyse

des Feldverhaltens verschiedener Generationen von Systemen leicht der Einfluss von Design- oder sonstigen Änderungen auf die Zuverlässigkeit bewertet werden. Die Anwendung solcher weiteren Nutzungsmöglichkeiten der Prognoseergebnisse werden anhand von praktischen Beispielen mit realen Garantiedaten gezeigt.

Für den Hersteller ist es oft besonders wichtig, schon frühzeitig Aussagen über die Produktzuverlässigkeit zu gewinnen. Wird das Produkt zum Zeitpunkt der Analyse jedoch noch gefertigt, dann sind die zur Verfügung stehenden Garantiedaten meist auf Grund eines Zulassungs- und Meldeverzugs noch unvollständig. Das entwickelte Zuverlässigkeitsprognosemodell wurde in dieser Arbeit für solche Fragestellungen erweitert und neue Ansätze entwickelt, die es ermöglichen, Zuverlässigkeitsprognosen auch auf Basis von unvollständigen Daten durchzuführen. Das für zeitnahe Daten erweiterte Modell wurde anhand umfangreicher Simulationen überprüft. Diese zeigen, dass der entwickelte Ansatz sehr gute Ergebnisse liefert. Des Weiteren wurden auch reale zeitnahe Garantiedaten eines Systems mit Hilfe des neuen Prognosemodells bewertet.

Die Zuverlässigkeit eines Systems hängt oft von weiteren Faktoren, wie den klimatischen Umgebungsbedingungen im Einsatzgebiet oder den Belastungen am Einbauort ab. Meist lassen sich solche Faktoren jedoch nur sehr schwer quantitativ beschreiben und deren Einfluss auf die Zuverlässigkeit der Komponente oder Baugruppe nur unzureichend funktional erfassen. Eine Möglichkeit, unbekannte funktionale Zusammenhänge zu modellieren und nutzbar zu machen, bieten die Neuronale Netze. Diese lernfähigen Algorithmen können dazu verwendet werden, selbständig Zusammenhänge in Datensätze zu erkennen und zu erlernen. Ein weiteres Ziel der Arbeit besteht darin, ein allgemeines, in der Praxis leicht anwendbares Modell zu entwickeln, das solche Einflussfaktoren bei den Zuverlässigkeitsprognosen berücksichtigt. Als Neuronales Modell wurden im Rahmen der Arbeit ein Multi Layered Perceptron-Netz verwendet. Dieses Netz eignet sich besonders zur Approximation unbekannter funktionaler Zusammenhänge zwischen endogenen und exogenen Variablen. Das neue Neuronale Zuverlässigkeitsprognosemodell wurde für Wischermotoren eines Mittelklassewagens in den USA entwickelt. Nach der Auswahl und Definition der relevanten Einflussfaktoren für die einzelnen US-Bundesstaaten, wurde anhand eines entwickelten Versuchplans eine optimale Netzkonfiguration ermittelt. Dazu wurden verschieden Netze mit unterschiedlicher Architektur, unterschiedlichen Lernverfahren- und Lernparametern sowie unterschiedlicher Vorverarbeitung der Daten erstellt, trainiert und anhand verschiedener Gütemaße bewertet. Mit Hilfe dieser Untersuchungen konnten verschiedene Neuronale Netze entwickelt werden, die das Ausfallverhalten bzw. die Ausfallwahrscheinlichkeit

des ausgewählten Wischermotors bei sich ändernden Umgebungsbedingungen prognostizieren.

Der neuronale Ansatz zur Beschreibung zusätzlicher Einflussfaktoren auf die Zuverlässigkeit von Systeme im Kraftfahrzeug stellt somit eine erhebliche Erweiterung und praktische Ergänzung der zuvor entwickelten Prognosemodelle dar. Die allgemeine Vorgehensweise zur Entwicklung eines neuronalen Modells für die funktionale Beschreibung von externen Einflussfaktoren lässt sich auch leicht auf andere Fragestellungen anwenden. So könnten in weiteren Untersuchungen beispielsweise die Einflüsse der Testparameter bei Lebensdauerprüfungen genauer untersucht und damit exaktere Ruffungsmodelle erstellt werden. Sieht man Neuronale Netze als eine Ergänzung bzw. neue Methode der Statistik an, lassen sich noch eine Vielzahl weiterer praktischer Anwendungen für Sicherheits- und Zuverlässigkeitsbetrachtungen beliebiger technischer Systeme entwickeln.



## 8 Literatur

- [And72] **Anderson, J. A.:** *A simple neural network generating an interactive memory.* Mathematical Biosciences, 14, 1972
- [And97] **Anders, U.:** *Statistische Neuronale Netze.* Franz Vahlen Verlag, München, 1997
- [Ans61] **Anscombe, F. J.:** *Estimating a Mixed-Exponential Response Law.* Journal of the American Statistical Association, 56, 1961.
- [Ans94] **Ansell, J. I. ; Phillips, M. J.:** *Practical Methods for Reliability Data Analysis.* Oxford University Press Inc., New York, 1994.
- [Bax90] **Baxt, W. G.:** *Use of an Artificial Neural Network for Data Analysis in Clinical Decision Making: The Diagnosis of Acute Coronary Occlusion.* Neural Computation, 2, 1990
- [Big02] **Biganzoli, E.; Boracchi, P.; Marubini, E.:** *A general framework for neural network models on censored survival data.* Neural Networks, 15, 209-218, 2002
- [Bir91] **Biolini, A.:** *Qualität und Zuverlässigkeit technischer Systeme.* 3. Auflage, Springer-Verlag, Berlin, 1991.
- [Blu75] **Blumenthal, S.; Marcus, R.:** *Estimating Population Size with Exponential Failure.* Journal of the American Statistical Association, 70, 1975.
- [Blu87] **Blume, H.:** *USA: Eine geographische Landeskunde.* Wissenschaftliche Länderkunde, Band 9, Wissenschaftliche Buchgesellschaft, Darmstadt, 1987.
- [Bra95] **Brause, R.:** *Neuronale Netze.* Teubner Verlag, Stuttgart, 1995
- [Bsc02] **Robert Bosch GmbH (Hrsg.):** *Lichttechnik und Scheibenreinigung am Kraftfahrzeug.* Gelbe Reihe, Fachwissen Kfz-Technik, 2002
- [Bsc98] **Robert Bosch GmbH (Hrsg.):** *Autoelektrik, Autoelektronik.* 3. Auflage, Vieweg Verlag, Braunschweig, Wiesbaden, 1998.
- [Cox72] **Cox, D. R.:** *Regression models and life tables (with discussion).* Journal of the Royal Statistics Society, B, 34, 187-220, 1972.
- [Cyb89] **Cybenko, G.:** *Approximation by Superpositions of a Sigmoidal Function.* Mathematics of Control, Signals, and Systems, 2, 1989.

- [Dai02] **Dais, S. :** *Hardware oder Software: Wer bestimmt Funktion und Charakter eines Fahrzeugs?* 11. Aachener Kolloquium Fahrzeug- und Motorentechnik, 2002.
- [Dra81] **Draper, N. R.; Smith, H.:** *Applied Regression Analysis*. Wiley Series in Probability and Mathematical Statistics, John Wiley & Sons, New York, Chichester, 1981.
- [Eck77] **Eckel, G.:** *Bestimmung des Anfangsverlaufs der Zuverlässigkeitsfunktion von Automobilteilen*. Qualität und Zuverlässigkeit, 9, Carl Hanser Verlag, München, 1977.
- [Fah88] **Fahlman, S. E.:** *An Empirical Study of Learning Speed in Back-Propagation Networks*. Technical Report CMU-CS-88-162, Dept. of Comp. Sc., Carnegie Mellon University, Pittsburgh, 1988.
- [Far77] **Farewell, V. T.:** *A model for a binary variable with time-censored observations*. Biometrika, 64:1, 1977.
- [Far82] **Farewell, V.T.:** *The Use of Mixture Models for the Analysis of Survival Data with Long-Term Survivors*. Biometrics, 38,1982.
- [Far95] **Farragi, D.; Simon, R.:** *An neural network model for survival data*. Statistics in Medicine, 14, 73-82, 1995.
- [Far97] **Farragi, D.Simon, R.; Yaskil, E.; Kramer, A.:** *Bayesian neural network models for censored data*. Biometrical Journal, 39, 519-532, 1997.
- [Fuj92] **Fujita, H.; Katafuchi, T.; Uehara, T.; Nishimura, T.:** *Application of Artificial Neural Network to Computer-Aided Diagnosis of Coronary Artery Disease in Myocardial Spect Bull's-Eyes Images*. Journal of Nuclear Medicine, 33 (2), 1992.
- [Gem92] **Geman, S.; Bienenstock, E.; Doursat, R.:** *Neural Networks and the Bias/Variance Dilemma*. Neural Computing, 4, 1-58, 1992.
- [Gor88] **Gorman, R. P.; Sejnowski, T. J.:** *Analysis of Hidden Units in a Layered Network to Classify Sonar Targets*. Neural Networks, 1, 1988.
- [Gov82] **Govil, K. K.; Aggarwal, K. K.:** *Modeling Early, Chance and Wearout Failures by a Single Failure Rate Equation*. Reliability Engineering, 3:5, 1982.

- [Hah82] **Hahn, G. D.:** *Pitfalls and Practical Considerations in Product Life Analysis-Part II: Mixtures of Product Population an More General Models.* Journal of Quality Technology, 14:4, 1982.
- [Hah91] **Hahn, G. J.; Meeker, W. Q.:** *Statistical Intervals: A Guide for Practitioners.* John Wiley & Sons, New York, 1991.
- [Har98] **Hartung, J.:** *Statistik: Lehr- und Handbuch der angewandten Statistik.* 11. Auflage, Oldenbourg Verlag, München, Wien, 1998.
- [Heb49] **Hebb, J.:** *The Organization of Behaviour.* John Wiley, New York, 1949
- [Heu97] **Heuer, J.:** *Neuronale Netze in der Industrie.* Deutscher Universitäts-Verlag, Wiesbaden, 1997
- [Hjo80] **Hjorth, U.:** *A Reliability Distribution with Increasing, Decreasing, Constant and Bath-Tub Shaped Failure Rate Equation.* Technometrics, 22:1, 1980.
- [Hof93] **Hoffmann, N.:** *Kleines Handbuch neuronale Netze.* Vieweg Verlag, Braunschweig, Wiesbaden, 1993
- [Hop85] **Hopfield, J.; Tank, D.:** *Neural Computations of Decisions in Optimization Problems.* Biological Cybernetics, 52, 1985
- [Hut94] **Hutchinson, J. M.:** *A Radial Basis Function Approach to Financial Time Series Analysis.* Ph.D. Dissertation, Massachusetts Institute of Technology, 1994
- [Kal88] **Kalbfleisch, J. D.; Lawless, J. F.:** *Estimation of Reliability in Field Performance Studies.* Technometrics, 30:4,365-378,1988.
- [Kap58] **Kaplan, E. L.; Meier, P.:** *Nonparametric estimation from incomplete observations.* Journal of the American Statistical Association, 53, 1958.
- [KBA03] **Kraftfahrt-Bundesamt:** *Jahrespressebericht 2003.*
- [Kec71] **Kececioglu, D., Starsman, R. R.:** *Reliability Life Testing of Mixed Early, Chance and Wearout Subpopulations.* Transactions of the 25<sup>th</sup> Annual ASQC Technical Conference, Chicago, 1971
- [Kec91] **Kececioglu, D.:** *Reliability Engineering Handbook.* Vol. 1, Prentice-Hall, New Jersey, 1991.
- [Kin94] **Kinnebrock, W.:** *Neuronale Netze.* Oldenbourg Verlag, München, Wien, 1994

- [Kle97] **Klein, J.P.; Moeschberger, M.L.:** *Survival Analysis. Techniques for Censored and Truncated Data.* Springer Verlag, New York, 1997.
- [Köc83] **Köchel, P.:** *Zuverlässigkeit technischer Systeme: Mathematische Methoden für Anwender.* Harri Deutsch Verlag, Thun, 1983.
- [Koh72] **Kohonen, T.:** *Correlation Matrix Memories.* IEEE Transactions on Computers, C-21, 1972
- [Koh82] **Kohonen, T.:** *Self-organized formation of topologically correct feature maps.* Biological Cybernetics, 43, 1982
- [Koh84] **Kohonen, T.:** *Self-Organization and Associative Memory.* Springer Verlag, Berlin, 1984
- [Law82] **Lawless, J.F.:** *Statistical Models and Methods for Lifetime Data.* John Wiley & Sons, Inc, New York, 1982.
- [Law98] **Lawless, J.F.:** *Statistical Analysis of Product Warranty Data.* International Statistical Review, 66:1,41-60, 1998.
- [Liu95] **Liu, M.C.; Kuo, W.; Sastri, T.:** *An exploratory study of a neural network approach for reliability data analysis.* Quality and Reliability Engineering International, 11, 107-112, 1995.
- [Llo79] **Lloyd, M. D.; Joe, G. W.:** *Recidivism Comparisons Across Groups: Methods of Estimating and Tests of Significance for Recidivism Rates and Asymptotes.* Evaluation Quarterly, 3, 1979.
- [Lux95] **Luxhoj, J. T.; Shyur, H.-J.:** *Reliability Curve fitting for aging helicopter components.* Reliability Engineering and System Safety, 48, 229-234, 1995.
- [Lux97] **Luxhoj, J. T.; Shyur, H.-J.:** *Comparison of proportional hazards models and neural networks for reliability estimation.* Journal of Intelligent Manufacturing, 8, 227-234, 1997.
- [Mah98] **van Mahnen, J.:** *Beitrag zur neuronalen Schätzung von Verteilungsparametern in der Technischen Zuverlässigkeit.* Fortschrittsbericht, VDI Reihe 20, Nr. 269, VDI Verlag, Düsseldorf, 1998.
- [Mai76] **Maibaum, G.:** *Wahrscheinlichkeitstheorie und mathematische Statistik.* VEB Deutscher Verlag der Wissenschaft, Berlin, 1976.
- [Mal77] **Maltz, M. D.; McCleary, R.:** *The Mathematics of Behavioral Change: Recidivism and Construct Validity.* Evaluation Quarterly, 1, 1977.

- [Mar97] **Mariani, L.; Coradini, D.; Biganzoli, E.; Boracchi, P.; Marubini, E.; Pilotti, S.; Salvatori, B.; Silvestrini, R.; Veronesi, U.; Zucali, R.; Rilke, F.:** *Prognostic factors for metachronous contralateral breast cancer: A comparison of the linear Cox regression model and its artificial neural network extension.* Breast Cancer Research and Treatment, 44, 167-178. 1997.
- [Mcc43] **McCulloch, W. S.; Pitts, W.:** *A logical Calculus of Ideas Imminent in Nervous Activity.* Bulletin of Mathematical Biophysics, 5, 1943
- [Mcc90] **McCullagh, P.; Nelder, J. A.:** *Generalized Linear Models.* Monographs on Statistics and Applied Probability, 37, Chapman and Hall, London, New York, 1990.
- [Mee87] **Meeker, W. Q.:** *Limited Failure Population Life Test: Application to Integrated Circuit Reliability.* Technometrics, 29:1, 1987.
- [Mee98] **Meeker, W. Q.; Escobar, L. E.:** *Statistical Methods for Reliability Data.* Wiley Series in Probability and Statistics, John Wiley & Sons, New York, Chichester, Weinheim, 1998.
- [Mer01] **Mercer Management Consulting (Hrsg.):** *Studie Automobiltechnologie 2010.* München, 2001.
- [Myr03] **Meyer, M. ; Meyna, A. ; Pauli, B. :** *Zuverlässigkeitsprognose für Kfz-Komponenten bei zeitnahen Garantiedaten.* ATZ Automobiltechnische Zeitschrift, 105:3, S. 262-267, 2003
- [Mey03] **Meyna, A.; Pauli, B.:** *Taschenbuch der Zuverlässigkeits- und Sicherheitstechnik: Quantitative Verfahren.* Praxisreihe Qualitätswissen, Carl Hanser Verlag, München, Wien, 2003.
- [Mey94] **Meyna, A.:** *Zuverlässigkeitsbewertung zukunftsorientierter Technologien.* 1. Auflage, Vieweg Verlag Braunschweig, 1994.
- [Min69] **Minsky, M.; Papert S.:** *Perceptrons: An Introduction to Computational Geometry.* MIT Press, Cambridge, Massachusetts, 1969
- [Mye02] **Myers, R. H.; Montgomery, D. C.; Vining, G. G.:** *Generalized Linear Models- With Applications in Engineering and the Sciences.* Wiley Series in Probability and Statistics, John Wiley & Sons, New York, 2002

- [NOA02] **National Oceanic And Atmospheric Administration, U.S. Department Of Commerce (Hrsg.):** *State, Regional, and National Seasonal Temperature and Precipitation-Weighted by Area*. Historical Climatology Series, Nr. 4-3, 2002.
- [Ott95] **Otto, P.:** *Identifikation nichtlinearer Systeme mit Künstlichen Netzen*. AT, 43, 2, Oldenbourg-Verlag, 62-68, 1995.
- [Pau00] **Pauli, B.; Meyna, A.:** *Zuverlässigkeitsprognosen für Kfz-Komponenten bei unvollständigen Daten*. ATZ Automobiltechnische Zeitschrift, 102:12, 2000.
- [Pau98] **Pauli, B.:** *Zuverlässigkeitsprognosen für elektronische Steuergeräte im Kraftfahrzeug*. Shaker Verlag, Aachen, 1998.
- [Pau99] **Pauli, B.:** *Eine neue Methode zur Bestimmung der kilometerabhängigen Lebensdauervertelung von Kfz-Komponenten*. ATZ Automobiltechnische Zeitschrift, 101:4, 1999.
- [Pon02] **Ponticel, P.:** *Interest strong in 42-V technologies*. Automotive Engineering International, 12, 2002.
- [Pro02] **Proskawetz, K.-O.:** *3. Braunschweiger Symposium: Automatisierungs- und Assistenzsysteme für Transportmittel*. Tagungsbericht, ATZ Automobiltechnische Zeitschrift, 104:6, 2002.
- [Roj93] **Rojas, R.:** *Theorie der neuronalen Netze*. Springer Verlag, Berlin, Heidelberg, New York, 1993
- [Ros58] **Rosenblatt, F.:** *The perceptron: a probabilistic model for information storage and organization in the brain*. Psychological Review, 65, 1958
- [Rum86] **Rumelhart, D. E.; Hinton, G. E.; Williams, R. J.:** *Learning representations by back-propagating errors*. Nature, 323, 1986
- [Sch93] **Schmidt, E.:** *Wischer und Waschanlagen für Fahrzeuge*. Die Bibliothek der Technik 80. Verlag Moderne Industrie, 1993.
- [Sil91] **Silbernagel, S.; Despopoulos, A.:** *Taschenatlas der Physiologie*. 4. überarb. Auflage, Thieme Verlag, Stuttgart, New York, München, 1991.
- [Ste81] **Steinhurst, W. R.:** *Hypothesis Tests for Limited Failure Survival Distributions*. Evaluation Review, 5, 1981.

- [Suz85a] **Suzuki, K.:** Nonparametric Estimation of Lifetime Distributions From a Record of Failures and Follow-ups. *Journal of the American Statistical Association*, 80:389, 68-72,1985.
- [Suz85b] **Suzuki, K.:** *Estimation of Lifetime Parameters From Incomplete Field Data*. *Technometrics*,27:3, 236-271,1985.
- [VDA84] **Verband der Automobilindustrie e.V. (Hrsg.):** *Zuverlässigkeitssicherung bei Automobilherstellern und Lieferanten*. Reihe Qualitätsmanagement in der Automobilindustrie, Band 3, 2.Auflage, Frankfurt, 1984.
- [VDA96] **Verband der Automobilindustrie e.V. (Hrsg.):** *Tatsachen und Zahlen aus der Kraftverkehrswirtschaft*. 60. Folge, Frankfurt, 1996.
- [War96] **Warner, B.; Misra, M.:** *Understanding Neural Networks as Statistical Tools*. *The American Statistician*, 50 (2), 1996
- [Wel89] **Weller, P. A.:** *Fachkunde Fahrzeugtechnik*. Holland + Josenhans Verlag, Stuttgart, 1989.
- [Zel00] **Zell, A.:** *Simulation neuronaler Netze*. Oldenbourg Verlag, München, Wien, 2000
- [Zel99] **Zell, A. et Al.:** *SNNS User Manual*. Version 4.2, Universität Stuttgart, Universität Tübingen, 1999.

# A Anhang

## A.1 Verwendete Symbole

$X$	Zufallsvariable
$x$	Realisierung der Zufallsvariablen $X$
$\theta$	Parametervektor einer Funktion
$\hat{\theta}$	geschätzter Parametervektor einer Funktion
$m_k$	$k$ -te empirische Momente
$L(\theta   x)$	Likelihoodfunktion
$SSE$	Summe der Abweichungsquadrate (sum of squared error)
$\alpha$	Irrtumswahrscheinlichkeit
$\theta_n$	untere Vertrauensgrenze
$\theta_o$	obere Vertrauensgrenze
$e_i$	Eingangswert eines Neurons
$a_i$	Ausgangswert eines Neurons
$w_{ij}$	Gewichtsfaktor zwischen Neuron $i$ und Neuron $j$
$\Theta_i$	Schwellenwert des Neurons $i$
$Y_i$	zu erklärende, endogene Variable
$f_a(x)$	Aktivierungsfunktion
$f_{out}(x)$	Ausgabefunktion
$T$	Zufallsvariable der Lebensdauer
$F(t)$	Verteilungsfunktion der Lebensdauer, Ausfallwahrscheinlichkeit
$R(t)$	Überlebenswahrscheinlichkeit
$f(t)$	Ausfalldichte
$h(t)$	Ausfallrate



---

$E(T)$	mittlere Lebensdauer, Erwartungswert
$\tilde{F}(t)$	empirische Ausfallwahrscheinlichkeit
$\tilde{R}(t)$	empirische Überlebenswahrscheinlichkeit
$\tilde{f}(t)$	empirische Ausfalldichte
$\tilde{h}(t)$	empirische Ausfallrate
$n_0$	Grundgesamtheit
$n_a(t)$	kumulierte Anzahl der Ausfälle bis zum Zeitpunkt t
$n_b(t)$	Zahl der zum Zeitpunkt t noch funktionsfähigen Einheiten
$\Delta n_{a,i}$	Anzahl der Ausfälle im i-ten Intervall
$F_T(t)$	Ausfallwahrscheinlichkeit einer Teilpopulation
$S_G$	Zufallsvariable der Fahrleistung für die Garantiedauer
$S_B$	Zufallsvariable der Fahrleistung für die Betriebsdauer
$t_G$	Garantiedauer
$t_B$	Betriebsdauer
$L_G$	Verteilungsfunktion der Fahrleistung für die Garantiedauer
$n_k(s)$	korrigierte Gesamtzahl der Ausfälle bei Fahrstrecke s
$n_G(s)$	Gesamtzahl der Ausfällen bei Fahrstrecke s innerhalb der Garantiezeit
$Z_S$	Zufallsvariable der benötigten Zeitdauer für die Strecke s
$A_S$	Verteilungsfunktion von $Z_S$
$K$	Gesamtgarantiekosten
$k$	Kosten für einen Garantiefall
$\Delta K$	Änderung der Gesamtgarantiekosten
$M_S$	Serienersatzbedarf
$t_E$	Zeitpunkt Serienende
$t_P$	Zeitpunkt Produktionsende
$t_N$	Zeitpunkt Nachlieferungspflicht
$M_E$	Endbevorratungsmenge

$M_{ges}$	Gesamtersatzbedarf
$t_F$	Zeitpunkt Fertigung
$t_A$	Zeitpunkt Ausfall
$t_B$	Zeitpunkt Betrachtung (Analyse)
$t_Z$	Zeitpunkt Zulassung
$t_R$	Zeitpunkt Registrierung
$F_Z$	Verteilungsfunktion Zulassungsverzug
$n_F(t)$	Fertigungsmenge für $t$
$n_Z(t)$	Gesamtzahl zugelassener Fahrzeuge für $t$
$F_M(t)$	Verteilungsfunktion des Anmeldeverzuges
$n_{t_A, t_B}(s)$	korrigierte Anzahl von Ausfällen bei Fahrstrecke $s$ für $t_A$ in $t_B$
$n_{t_A}(s)$	registrierte Ausfälle bei Fahrstrecke $s$ für $t_A$
$N_M(s)$	korrigierte Gesamtzahl der Ausfälle bei Fahrstrecke $s$ (Meldeverzug)
$L_D(s)$	Fahrleistungsverteilung für spezifische Zulassungsmonate
$n_{t_Z, K}(s)$	korrigierte Anzahl von Ausfällen bei Fahrstrecke $s$ für $t_Z$
$n_{t_Z}(s)$	Anzahl der Ausfälle bei Fahrstrecke $s$ für $t_Z$
$N_{AN, K}(s)$	korrigierte Gesamtzahl der Ausfälle bei Fahrstrecke $s$ (Anwärterberechnung)
$\tilde{F}_K(s)$	korrigierte empirische Ausfallwahrscheinlichkeit
$z$	Vektor von Variablen
$\kappa$	Vektor der Regressionskoeffizienten
$\lambda$	Konstante Ausfallrate
$\lambda_0(t)$	Grundausfallrate, Basis-Ausfallrate
$RF_{AR}$	Raffungsfaktor Arrhenius -Modell
$TK$	Temperatur in °K
$E_a$	Aktivierungsenergie
$k_B$	Boltzmann -Konstante
$RF_{EY}$	Raffungsfaktor Eyring-Modell

---

$n_{VN}$	Anzahl verdeckter Neuronen
$n_{EN}$	Anzahl Eingangsneuronen
$n_{AN}$	Anzahl Ausgangsneuronen
$n_{TRAIN}$	Anzahl Trainingsmuster
$\hat{y}_i$	Netzausgabe
$\eta$	Lernrate Backpropagation - Verfahren
$\delta_j$	Fehlersignal
$\pi$	Momentum-Koeffizient
$MSE$	mittlerer quadratischer Fehler
$RMSE$	Wurzel aus MSE
$R^2$	multipler Determinationskoeffizient
W- $\beta$	Weibull-Parameter $\beta$
W-T	Weibull-Parameter T* (charakteristische Lebensdauer)
$\bar{\alpha}$	durchschnittlicher Schätzwert des Weibull-Parameters $\alpha$
$\bar{\beta}$	durchschnittlicher Schätzwert des Weibull-Parameters $\beta$
$\sigma_{\bar{\alpha}}$	Standardabweichung des durchschnittlichen Schätzwertes $\alpha$
$\sigma_{\bar{\beta}}$	Standardabweichung des durchschnittlichen Schätzwertes $\beta$
$v_{\bar{\alpha}}$	Variationskoeffizient des durchschnittlichen Schätzwertes von $\alpha$
$v_{\bar{\beta}}$	Variationskoeffizient des durchschnittlichen Schätzwertes von $\beta$
$KI$	Konfidenzintervall für die durchschnittlichen Schätzwerte

## A.2 Statistische Ergebnisse

### A.2.1 Untersuchte Systeme

#### Wischsysteme

**Tabelle A.1: Kenngrößen Wischermotor w\_alt\_1**

Verkaufsmenge	1 830 137	
Anzahl Ausfälle	203	
Fahrleistungsverteilung	$\mu$	$\sigma$
Parameter Lognormal-Verteilung (ML)	2,96451	0,715693
Erwartungswert [Tkm]	25,044	
Lebensdauerverteilungen	$\alpha$	$\beta$
Km-abhängige Kenngrößen (Weibull-Verteilung)	2,81262 E-05	0,45499
Ausfallrate bei 50 Tkm [1/Tkm]	1,52 ppm	
zeitabhängige Kenngrößen (Weibull-Verteilung)	1,1427 E-04	0,45331

**Tabelle A.2: Kenngrößen Wischermotor w\_alt\_2**

Verkaufsmenge	1 214 302	
Anzahl Ausfälle	741	
Fahrleistungsverteilung	$\mu$	$\sigma$
Parameter Lognormal-Verteilung (ML)	2,72821	0,751555
Erwartungswert [Tkm]	20,30	
Lebensdauerverteilungen	$\alpha$	$\beta$
Km-abhängige Kenngrößen (Weibull-Verteilung)	2,39141 E-04	0,340369
Ausfallrate bei 50 Tkm [1/Tkm]	6,16 ppm	
zeitabhängige Kenngrößen (Weibull-Verteilung)	6,25372 E-04	0,339723

**Tabelle A.3: Kenngrößen Wischermotor w\_alt\_3**

Verkaufsmenge	1 074 359	
Anzahl Ausfälle	649	
Fahrleistungsverteilung	$\mu$	$\sigma$
Parameter Lognormal-Verteilung (ML)	3,15138	0,706294
Erwartungswert [Tkm]	29,9883	
Lebensdauerverteilungen	$\alpha$	$\beta$
Km-abhängige Kenngrößen (Weibull-Verteilung)	1,5002 E-04	0,43203
Ausfallrate bei 50 Tkm [1/Tkm]	7,03 ppm	
zeitabhängige Kenngrößen (Weibull-Verteilung)	6,13257 E-04	0,42927

**Tabelle A.4: Kenngrößen Wischermotor w\_alt\_4**

Verkaufsmenge	680 796	
Anzahl Ausfälle	145	
Fahrleistungsverteilung	$\mu$	$\sigma$
Parameter Lognormal-Verteilung (ML)	2,93772	0,630245
Erwartungswert [Tkm]	23,019	
Lebensdauerverteilungen	$\alpha$	$\beta$
Km-abhängige Kenngrößen (Weibull-Verteilung)	3,7369 E-05	0,581515
Ausfallrate bei 50 Tkm [1/Tkm]	4,23 ppm	
zeitabhängige Kenngrößen (Weibull-Verteilung)	2,20592 E-04	0,580706

**Tabelle A.5: Kenngrößen Wischermotor w\_alt\_5**

Verkaufsmenge	82 075	
Anzahl Ausfälle	35	
<b>Fahrleistungsverteilung</b>	$\mu$	$\sigma$
Parameter Lognormal-Verteilung (ML)	3,11918	0,645467
Erwartungswert [Tkm]	27,8683	
<b>Lebensdauerverteilungen</b>	$\alpha$	$\beta$
Km-abhängige Kenngrößen (Weibull-Verteilung)	6,48566 E-05	0,604946

Ausfallrate bei 50 Tkm [1/Tkm]	8,36 ppm	
zeitabhängige Kenngrößen (Weibull-Verteilung)	4,61881 E-04	0,602619

**Tabelle A.6: Kenngrößen Wischermotor w\_alt\_6**

Verkaufsmenge	998 427	
Anzahl Ausfälle	225	
Fahrleistungsverteilung	$\mu$	$\sigma$
Parameter Lognormal-Verteilung (ML)	3,13065	0,789522
Erwartungswert [Tkm]	31,2595	
Lebensdauerverteilungen	$\alpha$	$\beta$
Km-abhängige Kenngrößen (Weibull-Verteilung)	4,10286 E-05	0,529024
Ausfallrate bei 50 Tkm [1/Tkm]	3,44 ppm	
zeitabhängige Kenngrößen (Weibull-Verteilung)	2,34544 E-04	0,521687

**Tabelle A.7: Kenngrößen Wischermotor w\_alt\_7**

Verkaufsmenge	719 310	
Anzahl Ausfälle	73	
Fahrleistungsverteilung	$\mu$	$\sigma$
Parameter Lognormal-Verteilung (ML)	3,26578	0,633553
Erwartungswert [Tkm]	32,0236	
Lebensdauerverteilungen	$\alpha$	$\beta$
Km-abhängige Kenngrößen (Weibull-Verteilung)	1,29019 E-05	0,630578
Ausfallrate bei 50 Tkm [1/Tkm]	1,92 ppm	
zeitabhängige Kenngrößen (Weibull-Verteilung)	1,09562 E-04	0,626743

**Tabelle A.8: Kenngrößen Wischermotor w\_neu (zeitnahe Prognose)**

Verkaufsmenge	3 127 892	
Anzahl Ausfälle	66	
Verteilung Zulassungsverzug	$\mu$	$\sigma$

Parameter Lognormal-Verteilung (ML)	0,947649	0,747076
Verteilung Meldeverzug	$\mu$	$\sigma$
Parameter Lognormal-Verteilung (ML)	0,954588	0,458463
Verteilung Fahrleistung	$\mu$	$\sigma$
Parameter Lognormal-Verteilung (ML)	3,18947	0,642532
Erwartungswert [Tkm]	29,8414	
Lebensdauerverteilungen	$\alpha$	$\beta$
Km-abhängige Kenngrößen (Weibull-Verteilung)	3,11315 E-05	0,554246
Ausfallrate bei 50 Tkm [1/Tkm]	3,02 ppm	
zeitabhängige Kenngrößen (Weibull-Verteilung)	1,94294 E-04	0,551745

## Kupplungsteller

**Tabelle A.9: Kenngrößen Kupplungsteller (entwickeltes Ausfallmodell)**

Verkaufsmenge	68 130	
Anzahl Ausfälle	93	
Verteilung Fahrleistung	$\mu$	$\sigma$
Parameter Lognormal-Verteilung (ML)	2,87273	0,833825
Ausfallwahrscheinlichkeit $F_{11}$	$\alpha$	$\beta$
Km-abhängige Kenngrößen (Weibull-Verteilung)	0,282492	0,749693
Umfang der Teilpopulation $n_{11}$	71,3	
Ausfallwahrscheinlichkeit $F_2$	$\alpha$	$\beta$
Km-abhängige Kenngrößen (Weibull-Verteilung)	1,49009 E-04	0,350926
Ausfallrate bei 50 Tkm [1/Tkm]	4,54 ppm	

## Steuergeräte

**Tabelle A.10: Kenngrößen SG\_1**

Verkaufsmenge	331 439	
Anzahl Ausfälle	203	
Verteilung Fahrleistung	$\mu$	$\sigma$
Parameter Lognormal-Verteilung (ML)	3,77192	0,715548

Erwartungswert [Tkm]	56,1444
----------------------	---------

## Ausfallmodell 1

Ausfallwahrscheinlichkeit $F_T$	$\alpha$	$\beta$
Km-abhängige Kenngrößen (Weibull-Verteilung)	0,0400447	1,03176
Umfang der Teilpopulation $n_T$	234,566	
Ausfallrate bei 50 Tkm [1/Tkm]	3,43 ppm	

## Ausfallmodell 2

Ausfallwahrscheinlichkeit $F_{11}$	$\alpha$	$\beta$
Km-abhängige Kenngrößen (Weibull-Verteilung)	0,0438686	0,963187
Umfang der Teilpopulation $n_{11}$	235,575	
Ausfallwahrscheinlichkeit $F_2$	$\alpha$	$\beta$
Km-abhängige Kenngrößen (Weibull-Verteilung)	4,81171 E-6	0,475516
Ausfallrate bei 50 Tkm [1/Tkm]	4,19 ppm	

Tabelle A.11: Kenngrößen SG\_2

Verkaufsmenge	35 059	
Anzahl Ausfälle	351	
Verteilung Fahrleistung	$\mu$	$\sigma$
Parameter Lognormal-Verteilung (ML)	3,75411	0,53211
Erwartungswert [Tkm]	49,1893	

## Ausfallmodell 1

Ausfallwahrscheinlichkeit $F_T$	$\alpha$	$\beta$
Km-abhängige Kenngrößen (Weibull-Verteilung)	8,84914 E-04	1,85962
Umfang der Teilpopulation $n_T$	590,8	
Ausfallrate bei 50 Tkm [1/Tkm]	225,942 ppm	

## Ausfallmodell 2

Ausfallwahrscheinlichkeit $F_{11}$	$\alpha$	$\beta$
------------------------------------	----------	---------



Km-abhängige Kenngrößen (Weibull-Verteilung)	4,45607 E-05	2,70674
Umfang der Teilpopulation $n_{11}$	352,84	
Ausfallwahrscheinlichkeit $F_2$	$\alpha$	$\beta$
Km-abhängige Kenngrößen (Weibull-Verteilung)	2,12832 E-04	0,752651
Ausfallrate bei 50 Tkm [1/Tkm]	226,61 ppm	

Tabelle A.12: Kenngrößen SG\_3

Verkaufsmenge	122 754	
Anzahl Ausfälle	147	
Verteilung Fahrleistung	$\mu$	$\sigma$
Parameter Lognormal-Verteilung (ML)	3,68569	0,603499
Erwartungswert [Tkm]	47,8367	

## Ausfallmodell 1

Ausfallwahrscheinlichkeit $F_T$	$\alpha$	$\beta$
Km-abhängige Kenngrößen (Weibull-Verteilung)	7,37753 E-03	1,43455
Umfang der Teilpopulation $n_T$	206,03	
Ausfallrate bei 50 Tkm [1/Tkm]	12,93 ppm	

## Ausfallmodell 2

Ausfallwahrscheinlichkeit $F_{11}$	$\alpha$	$\beta$
Km-abhängige Kenngrößen (Weibull-Verteilung)	6,36581 E-03	1,50737
Umfang der Teilpopulation $n_{11}$	175,348	
Ausfallwahrscheinlichkeit $F_2$	$\alpha$	$\beta$
Km-abhängige Kenngrößen (Weibull-Verteilung)	4,92673 E-06	0,896942
Ausfallrate bei 50 Tkm [1/Tkm]	12,80 ppm	

**Tabelle A.13: Kenngrößen SG\_4**

Verkaufsmenge	28 414	
Anzahl Ausfälle	109	
Verteilung Fahrleistung	$\mu$	$\sigma$
<b>Parameter Lognormal-Verteilung (ML)</b>	3,79566	0,658648
Erwartungswert [Tkm]	55,2889	

## Ausfallmodell 1

Ausfallwahrscheinlichkeit $F_T$	$\alpha$	$\beta$
Km-abhängige Kenngrößen (Weibull-Verteilung)	0,0174793	0,903017
Umfang der Teilpopulation $n_T$	286,996	
Ausfallrate bei 50 Tkm [1/Tkm]	60,26 ppm	

## Ausfallmodell 2

Ausfallwahrscheinlichkeit $F_{11}$	$\alpha$	$\beta$
Km-abhängige Kenngrößen (Weibull-Verteilung)	3,85168 E-03	1,71362
Umfang der Teilpopulation $n_{11}$	81,688	
Ausfallwahrscheinlichkeit $F_2$	$\alpha$	$\beta$
Km-abhängige Kenngrößen (Weibull-Verteilung)	1,47604 E-06	0,627754
Ausfallrate bei 50 Tkm [1/Tkm]	35,0204 ppm	

## A.2.2 Simulation zeitnaher Daten

### Szenario 1:

Grundgesamtheit: 15 000

Garantiezeit: 12 Monate

Anzahl Simulationen: 100

Zufallsgröße	Verteilungsmodell	Parameter	
$F_Z$	$LN(\mu, \sigma^2)$	$\mu = 0,958$	$\sigma = 0,7765$
$F_M$	$LN(\mu, \sigma^2)$	$\mu = 0,940$	$\sigma = 0,5147$
$L_G$	$LN(\mu, \sigma^2)$	$\mu = 3,03$	$\sigma = 0,82$
$F(s)$	$W(\alpha, \beta)$	$\alpha = 0,003981$	$\beta = 0,4$

Methode	$\bar{\alpha}$	$\sigma_{\bar{\alpha}}$	$v_{\bar{\alpha}}$	$KI(\bar{\alpha})_{0,95}$	$\bar{\beta}$	$\sigma_{\bar{\beta}}$	$v_{\bar{\beta}}$	$KI(\bar{\beta})_{0,95}$
LR	0,0039796	0,00087577	0,220066	[0,00380493; 0,00415428]	0,394538	0,0941135	0,238541	[0,375768; 0,413309]
KQ	0,00382598	0,00135398	0,353892	[0,00355309; 0,00409886]	0,434297	0,205548	0,47329	[0,392869; 0,475724]
ML	0,00265491	0,00374298	1,40983	[0,00189652; 0,00341331]	0,551692	0,0602128	0,109142	[0,539492; 0,563892]

### Szenario 2:

Grundgesamtheit: 35 000

Garantiezeit: 12 Monate

Anzahl Simulationen: 100

Zufallsgröße	Verteilungsmodell	Parameter	
$F_Z$	$LN(\mu, \sigma^2)$	$\mu = 0,958$	$\sigma = 0,7765$
$F_M$	$LN(\mu, \sigma^2)$	$\mu = 0,940$	$\sigma = 0,5147$
$L_G$	$LN(\mu, \sigma^2)$	$\mu = 3,03$	$\sigma = 0,82$
$F(s)$	$W(\alpha, \beta)$	$\alpha = 0,000513714$	$\beta = 0,7$

Methode	$\bar{\alpha}$	$\sigma_{\bar{\alpha}}$	$v_{\bar{\alpha}}$	$KI(\bar{\alpha})_{0,95}$	$\bar{\beta}$	$\sigma_{\bar{\beta}}$	$v_{\bar{\beta}}$	$KI(\bar{\beta})_{0,95}$
LR	0,000517361	0,000167683	0,324113	[0,000484089; 0,000550633]	0,6982	0,132994	0,190482	[0,671811; 0,724588]
KQ	0,000532837	0,00025348	0,475718	[0,000480343; 0,000585331]	0,71961	0,232189	0,32266	[0,671525; 0,767695]
ML	0,000378673	0,000109627	0,289504	[0,000356219; 0,000401127]	0,76299	0,116139	0,151757	[0,741512, 0,789087]

**Szenario 3:**

Grundgesamtheit: 40 000

Garantiezeit: 12 Monate

Anzahl Simulationen: 100

Zufallsgröße	Verteilungsmodell	Parameter	
$F_Z$	$LN(\mu, \sigma^2)$	$\mu = 0,958$	$\sigma = 0,7765$
$F_M$	$LN(\mu, \sigma^2)$	$\mu = 0,940$	$\sigma = 0,5147$
$L_G$	$LN(\mu, \sigma^2)$	$\mu = 3,03$	$\sigma = 0,82$
$F(s)$	$W(\alpha, \beta)$	$\alpha = 0,0002$	$\beta = 1$

Methode	$\bar{\alpha}$	$\sigma_{\bar{\alpha}}$	$v_{\bar{\alpha}}$	$KI(\bar{\alpha})_{0,95}$	$\bar{\beta}$	$\sigma_{\bar{\beta}}$	$v_{\bar{\beta}}$	$KI(\bar{\beta})_{0,95}$
LR	0,000202459	0,0000710968	0,351166	[0,000188352; 0,000216566]	0,991841	0,151907	0,153157	[0,961699; 1,02198]

KQ	0,000271638	0,00019575	0,720628	[0,000231099; 0,000312176]	0,960366	0,238727	0,248579	[0,910927; 1,0098]
ML	0,000183493	0,0000528517	0,288031	[0,000172423; 0,000194563]	0,977465	0,105249	0,107676	[0,955421; 0,999509]

**Szenario 4:**

Grundgesamtheit: 30 000

Garantiezeit: 12 Monate

Anzahl Simulationen: 100

Zufallsgröße	Verteilungsmodell	Parameter	
$F_Z$	$LN(\mu, \sigma^2)$	$\mu = 0,958$	$\sigma = 0,7765$
$F_M$	$LN(\mu, \sigma^2)$	$\mu = 0,940$	$\sigma = 0,5147$
$L_G$	$LN(\mu, \sigma^2)$	$\mu = 3,03$	$\sigma = 0,82$
$F(s)$	$W(\alpha, \beta)$	$\alpha = 0,0000935946$	$\beta = 1,4$

Methode	$\bar{\alpha}$	$\sigma_{\bar{\alpha}}$	$v_{\bar{\alpha}}$	$KI(\bar{\alpha})_{0,95}$	$\bar{\beta}$	$\sigma_{\bar{\beta}}$	$v_{\bar{\beta}}$	$KI(\bar{\beta})_{0,95}$
LR	0,00011166	0,0000460761	0,412648	[0,00010247; 0,000120849]	1,36693	0,131852	0,0964581	[1,34063; 1,39323]
KQ	0,000148291	0,000175426	1,18299	[0,000110452; 0,000186129]	1,44732	0,326806	0,225802	[1,37683; 1,51781]
ML	0,000107187	0,0000476183	0,444254	[0,0000971563; 0,000117218]	1,35132	0,147386	0,109068	[1,32027; 1,38237]

### A.3 Neuronale Netze

Zum besseren Auffinden der Ergebnisse spezieller Netzkonfigurationen sind die folgenden Tabellen mit einem Code gekennzeichnet. Dieser entspricht einem Ausgangspfad des zugehörigen Versuchsplans. Der Aufbau des Codes kann Bild A.1 und Bild A.2 entnommen werden.

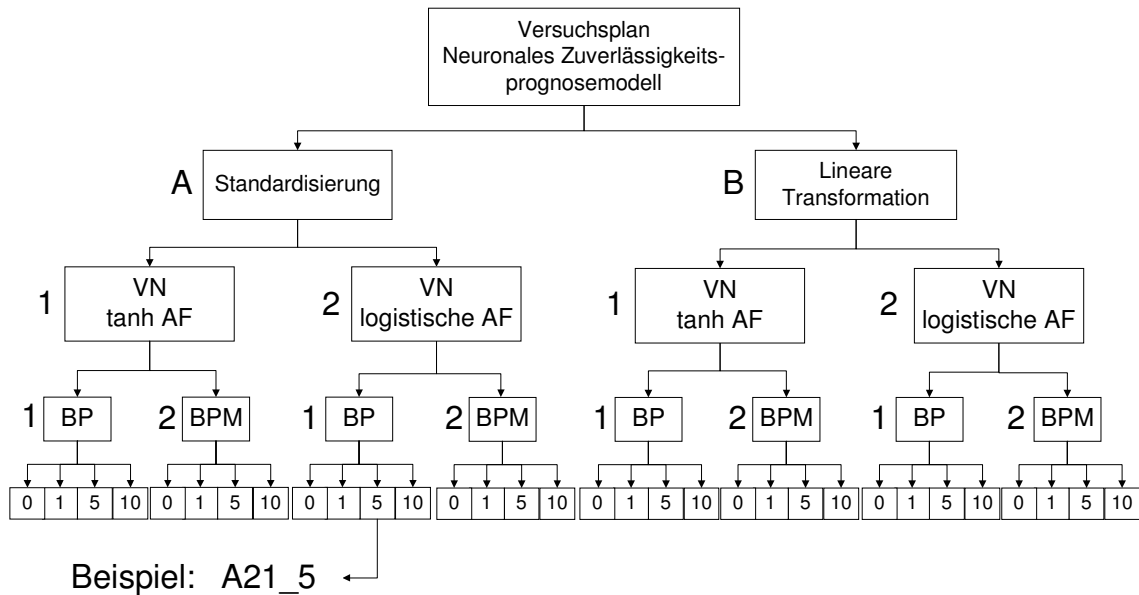


Bild A.1: Aufbau des Ergebnis-Codes für Datensatz 1

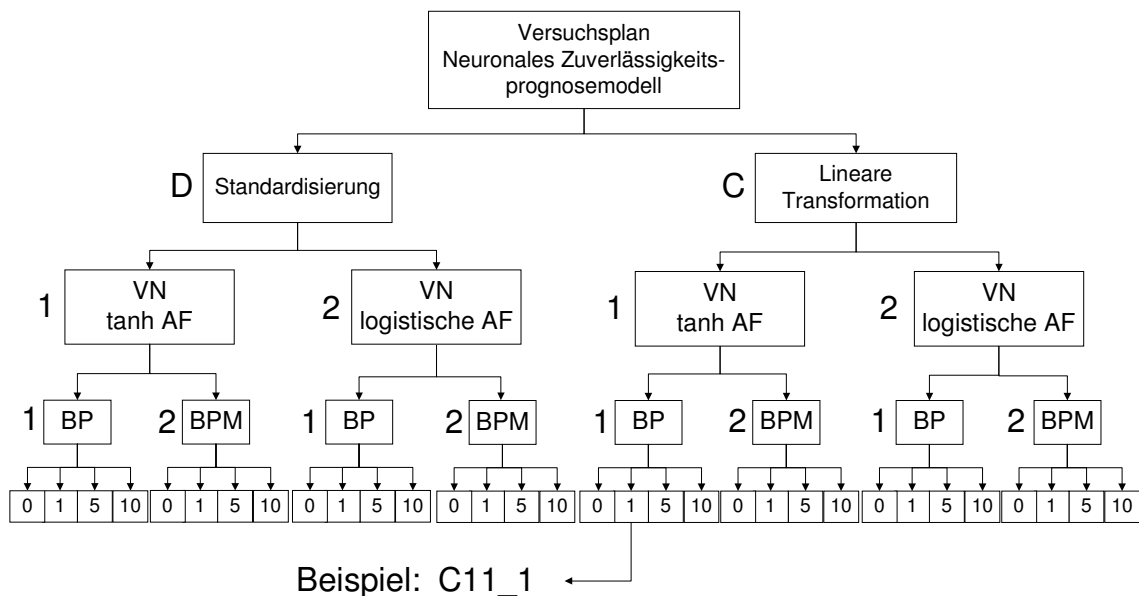


Bild A.2: Aufbau des Ergebnis-Codes für Datensatz 2

## A.3.1 Datensatz 1

Tabelle A.14: Kenngrößen Neuronales Netz (A11\_0)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momententerm $\pi$	
Standardisierung	tanh	BP	0,4	---	0
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
<b>SSE</b>	0,8727	0,5006	0,2209		
<b>R<sup>2</sup></b>	0,8748	0,7114	0,8265		
<b>MSE</b>	0,0044	0,0111	0,0085		
<b>RMSE</b>	0,0666	0,1055	0,0922		




Tabelle A.15: Kenngrößen Neuronales Netz (A11\_1)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Standardisierung	tanh	BP	0,4	---	1
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,3149	0,2653	0,1512		
$R^2$	0,9548	0,8471	0,8812		
MSE	0,0016	0,0062	0,0063		
RMSE	0,0402	0,0785	0,0794		






Tabelle A.16: Kenngrößen Neuronales Netz (A11\_5)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momententerm $\pi$	
Standardisierung	tanh	BP	0,4	---	5
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,0212	0,1133	0,4733		
$R^2$	0,9970	0,9347	0,6283		
MSE	0,0001	---	---		
RMSE	0,0122	---	---		




Tabelle A.17: Kenngrößen Neuronales Netz (A11\_10)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Standardisierung	tanh	BP	0,4	---	10
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,1212	0,2088	0.1603		
$R^2$	0,9826	0,8796	0.0,8741		
MSE	0,0016	---	---		
RMSE	0,0394	---	---		




Tabelle A.18: Kenngrößen Neuronales Netz (A12\_0)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Standardisierung	tanh	BPM	0,4	0,1	0
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
<b>SSE</b>	1,0992	0,4230	0,1954		
<b>R<sup>2</sup></b>	0,8424	0,7561	0,8466		
<b>MSE</b>	0,0056	0,0094	0,0075		
<b>RMSE</b>	0,0747	0,0970	0,0867		




Tabelle A.19: Kenngrößen Neuronales Netz (A12\_1)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Standardisierung	tanh	BPM	0,4	0,1	1
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,3724	0,4022	0,2572		
$R^2$	0,9466	0,7681	0,7980		
MSE	0,0019	0,0094	0,0107		
RMSE	0,0437	0,0967	0,1035		




Tabelle A.20: Kenngrößen Neuronales Netz (A12\_5)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Standardisierung	tanh	BPM	0,6	0,01	5
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,0870	0,1898	0,1153		
$R^2$	0,9875	0,8906	0,9095		
MSE	0,0006	---	---		
RMSE	0,0247	---	---		




Tabelle A.21: Kenngrößen Neuronales Netz (A12\_10)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momententerm $\pi$	
Standardisierung	tanh	BPM	0,4	0,1	10
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,1162	0,2661	0,1319		
$R^2$	0,9833	0,8466	0,8965		
MSE	0,0015	---	---		
RMSE	0,0386	---	---		




Tabelle A.22: Kenngrößen Neuronales Netz (A21\_0)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Standardisierung	Logistische Funktion	BP	0,4	---	0
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
<b>SSE</b>	0,8727	0,5006	0,2209		
<b>R<sup>2</sup></b>	0,8748	0,7114	0,8265		
<b>MSE</b>	0,0044	0,0111	0,0085		
<b>RMSE</b>	0,0666	0,1055	0,0922		




Tabelle A.23: Kenngrößen Neuronales Netz (A21\_1)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Standardisierung	Logistische Funktion	BP	0,4	---	1
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,3817	0,4140	0,2012		
$R^2$	0,9453	0,7613	0,8420		
MSE	0,0020	0,0096	0,0084		
RMSE	0,0442	0,0981	0,0916		






Tabelle A.24: Kenngrößen Neuronales Netz (A21\_5)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momententerm $\pi$	
Standardisierung	Logistische Funktion	BP	0,4	---	5
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
<b>SSE</b>	0,0368	0,2054	0,2708		
<b>R<sup>2</sup></b>	0,9947	0,8816	0,7874		
<b>MSE</b>	0,0003	---	---		
<b>RMSE</b>	0,0160	---	---		




Tabelle A.25: Kenngrößen Neuronales Netz (A21\_10)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momententerm $\pi$	
Standardisierung	Logistische Funktion	BP	0,4	---	10
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,0463	0,1355	0,1358		
$R^2$	0,9934	0,9219	0,8933		
MSE	0,0006	---	---		
RMSE	0,0244	---	---		




Tabelle A.26: Kenngrößen Neuronales Netz (A22\_0)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momententerm $\pi$	
Standardisierung	Logistische Funktion	BPM	0,4	0,1	0
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
<b>SSE</b>	1,0992	0,4230	0,1954		
<b>R<sup>2</sup></b>	0,8424	0,7561	0,8466		
<b>MSE</b>	0,0056	0,0094	0,0075		
<b>RMSE</b>	0,0747	0,0970	0,0867		




Tabelle A.27: Kenngrößen Neuronales Netz (A22\_1)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Standardisierung	Logistische Funktion	BPM	0,4	0,01	1
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,4272	0,4147	0,2704		
$R^2$	0,9387	0,7609	0,7877		
MSE	0,0022	0,0096	0,0113		
RMSE	0,0468	0,0982	0,1061		




Tabelle A.28: Kenngrößen Neuronales Netz (A22\_5)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Standardisierung	Logistische Funktion	BPM	0,4	0,01	5
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
<b>SSE</b>	0,0414	0,1432	0,1826		
<b>R<sup>2</sup></b>	0,9941	0,9174	0,8566		
<b>MSE</b>	0,0003	---	---		
<b>RMSE</b>	0,0170	---	---		




Tabelle A.29: Kenngrößen Neuronales Netz (A22\_10)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Standardisierung	Logistische Funktion	BPM	0,4	0,01	10
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,0632	0,1404	0,1796		
$R^2$	0,9909	0,9191	0,8589		
MSE	0,0008	---	---		
RMSE	0,0285	---	---		




Tabelle A.30: Kenngrößen Neuronales Netz (B11\_0)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momententerm $\pi$	
Lineare Transf.	tanh	BP	0,4	---	0
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
<b>SSE</b>	0,8488	0,5642	0,2269		
<b>R<sup>2</sup></b>	0,8783	0,6747	0,8218		
<b>MSE</b>	0,0043	0,0125	0,0087		
<b>RMSE</b>	0,0656	0,1120	0,0934		




Tabelle A.31: Kenngrößen Neuronales Netz (B11\_1)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momententerm $\pi$	
Lineare Transf.	tanh	BP	0,4	---	1
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,2920	0,3720	0,1785		
$R^2$	0,9581	0,7855	0,8598		
MSE	0,0015	0,0087	0,0074		
RMSE	0,0387	0,0930	0,0863		






Tabelle A.32: Kenngrößen Neuronales Netz (B11\_5)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Lineare Transf.	tanh	BP	0,4	---	5
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
<b>SSE</b>	0,1699	0,1964	0,0151		
<b>R<sup>2</sup></b>	0,9756	0,8868	0,9881		
<b>MSE</b>	0,0012	---	---		
<b>RMSE</b>	0,0345	---	---		




Tabelle A.33: Kenngrößen Neuronales Netz (B11\_10)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Lineare Transf.	tanh	BP	0,4	---	10
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,1476	0,1715	0,0226		
$R^2$	0,9788	0,9011	0,9823		
MSE	0,0019	---	---		
RMSE	0,0435	---	---		




Tabelle A.34: Kenngrößen Neuronales Netz (B12\_0)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momententerm $\pi$	
Lineare Transf.	tanh	BPM	0,4	0,1	0
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
<b>SSE</b>	0,8400	0,6415	0,2258		
<b>R<sup>2</sup></b>	0,8795	0,6302	0,8227		
<b>MSE</b>	0,0043	0,0143	0,0087		
<b>RMSE</b>	0,0653	0,1194	0,0932		




Tabelle A.35: Kenngrößen Neuronales Netz (B12\_1)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momententerm $\pi$	
Lineare Transf.	tanh	BPM	0,4	0,1	1
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,2908	0,4606	0,2027		
$R^2$	0,9583	0,7344	0,8409		
MSE	0,0015	0,0107	0,0084		
RMSE	0,0386	0,1035	0,0919		




Tabelle A.36: Kenngrößen Neuronales Netz (B12\_5)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Lineare Transf.	tanh	BPM	0,4	0,1	5
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,1681	0,1920	0,0190		
$R^2$	0,9759	0,8893	0,9851		
MSE	0,0012	---	---		
RMSE	0,0343	---	---		




Tabelle A.37: Kenngrößen Neuronales Netz (B12\_10)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Lineare Transf.	tanh	BPM	0,4	0,1	10
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,1872	0,1953	0,0325		
$R^2$	0,9732	0,8874	0,9745		
MSE	0,0024	---	---		
RMSE	0,0490	---	---		




Tabelle A.38: Kenngrößen Neuronales Netz (B21\_0)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momententerm $\pi$	
Lineare Transf.	Logistische Funktion.	BP	0,4	---	0
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
<b>SSE</b>	0,8488	0,5642	0,2269		
<b>R<sup>2</sup></b>	0,8783	0,6747	0,8218		
<b>MSE</b>	0,0043	0,0125	0,0087		
<b>RMSE</b>	0,0656	0,1120	0,0934		

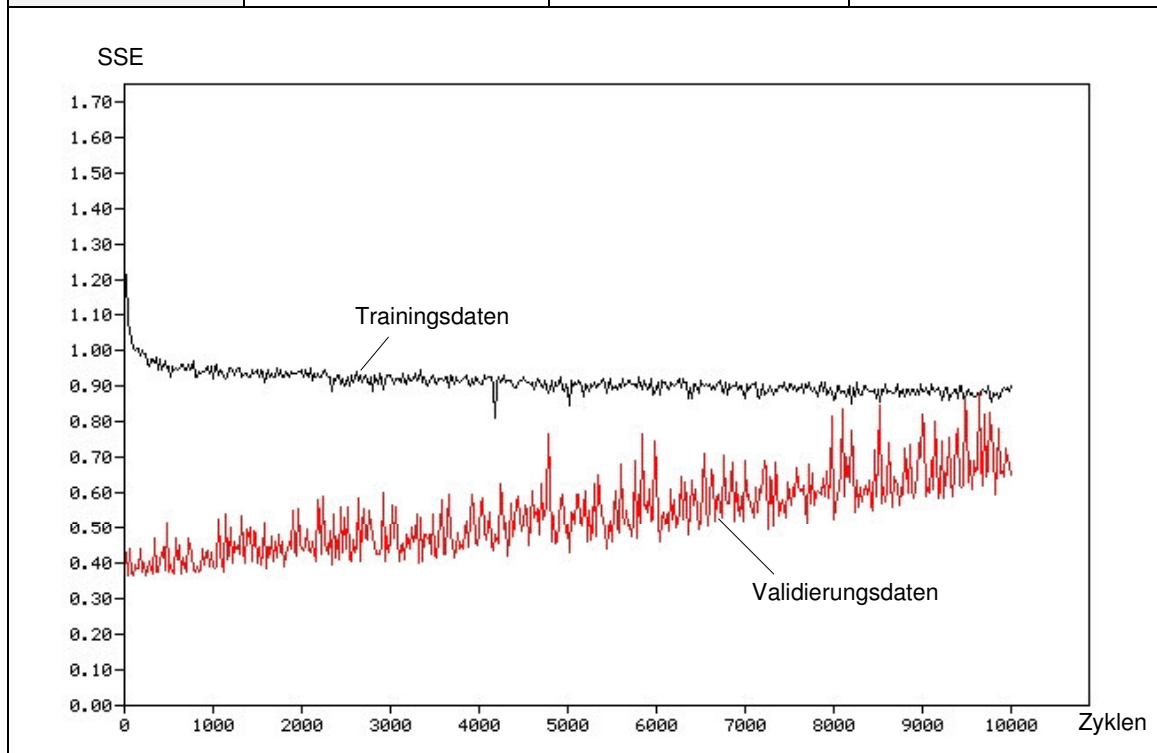


Tabelle A.39: Kenngrößen Neuronales Netz (B21\_1)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Lineare Transf.	Logistische Funktion.	BP	0,4	---	1
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,3143	0,2410	0,0805		
$R^2$	0,9549	0,8611	0,9368		
MSE	0,0016	0,0056	0,0034		
RMSE	0,0401	0,0749	0,0579		






Tabelle A.40: Kenngrößen Neuronales Netz (B21\_5)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Lineare Transf.	Logistische Funktion.	BP	0,6	---	5
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,1743	0,1985	0,0487		
$R^2$	0,9750	0,8856	0,9617		
MSE	0,0012	---	---		
RMSE	0,0349	---	---		




Tabelle A.41: Kenngrößen Neuronales Netz (B21\_10)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Lineare Transf.	Logistische Funktion.	BP	0,6	---	10
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,1602	0,1966	0,0519		
$R^2$	0,9770	0,8866	0,9593		
MSE	0,0021	---	---		
RMSE	0,0453	---	---		




Tabelle A.42: Kenngrößen Neuronales Netz (B22\_0)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momententerm $\pi$	
Lineare Transf.	Logistische Funktion	BPM	0,4	0,1	0
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,8400	0,6415	0,2258		
$R^2$	0,8795	0,6302	0,8227		
MSE	0,0043	0,0143	0,0087		
RMSE	0,0653	0,1194	0,0932		




Tabelle A.43: Kenngrößen Neuronales Netz (B22\_1)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Lineare Transf.	Logistische Funktion	BPM	0,4	0,1	1
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,3001	0,3256	0,1528		
$R^2$	0,9570	0,8123	0,8800		
MSE	0,0015	0,0076	0,0064		
RMSE	0,0392	0,0870	0,0798		




Tabelle A.44: Kenngrößen Neuronales Netz (B22\_5)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Lineare Transf.	Logistische Funktion	BPM	0,6	0,05	5
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,2028	0,2604	0,0835		
$R^2$	0,9709	0,8499	0,9345		
MSE	0,0014	---	---		
RMSE	0,0377	---	---		





Tabelle A.45: Kenngrößen Neuronales Netz (B22\_10)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Lineare Tranf.	Logistische Funktion	BPM	0,6	0,05	10
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,1836	0,2258	0,0538		
$R^2$	0,9737	0,8698	0,9577		
MSE	0,0024	---	---		
RMSE	0,0485	---	---		



## A.3.2 Datensatz 2

Tabelle A.46: Kenngrößen Neuronales Netz (C11\_0)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Lineare Tranf.	tanh	BP	0,5	---	0
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
<b>SSE</b>	0,5596	0,5162	0,5146		
<b>R<sup>2</sup></b>	0,8932	0,7871	0,7800		
<b>MSE</b>	0,0040	0,0081	0,0080		
<b>RMSE</b>	0,0632	0,0898	0,0897		




Tabelle A.47: Kenngrößen Neuronales Netz (C11\_1)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momententerm $\pi$	
Lineare Transf.	tanh	BP	0,5	---	1
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,2293	0,1558	0,1942		
$R^2$	0,9562	0,9357	0,9170		
MSE	0,0017	0,0025	0,0031		
RMSE	0,0408	0,0501	0,0560		






Tabelle A.48: Kenngrößen Neuronales Netz (C11\_5)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momententerm $\pi$	
Lineare Transf.	tanh	BP	0,5	---	5
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,1689	0,1917	0,3678		
$R^2$	0,9678	0,9209	0,8428		
MSE	0,0020	0,0192	0,0368		
RMSE	0,0443	0,1384	0,1918		




Tabelle A.49: Kenngrößen Neuronales Netz (C11\_10)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Lineare Transf.	tanh	BP	0,5	---	10
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,1558	0,1663	0,3254		
$R^2$	0,9702	0,9314	0,8609		
MSE	0,0074	---	---		
RMSE	0,0861	---	---		




Tabelle A.50: Kenngrößen Neuronales Netz (C12\_0)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Lineare Transf.	tanh	BPM	0,5	0,1	0
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
<b>SSE</b>	0,6344	0,6687	0,5916		
<b>R<sup>2</sup></b>	0,8789	0,7242	0,7471		
<b>MSE</b>	0,0045	0,0104	0,0092		
<b>RMSE</b>	0,0673	0,1022	0,0961		




Tabelle A.51: Kenngrößen Neuronales Netz (C12\_1)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Lineare Transf.	tanh	BPM	0,5	0,01	1
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
<b>SSE</b>	0,2233	0,1715	0,2057		
<b>R<sup>2</sup></b>	0,9574	0,9293	0,9121		
<b>MSE</b>	0,0016	0,0028	0,0033		
<b>RMSE</b>	0,0402	0,0526	0,0576		




Tabelle A.52: Kenngrößen Neuronales Netz (C12\_5)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momententerm $\pi$	
Lineare Transf.	tanh	BPM	0,5	0,01	5
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
<b>SSE</b>	0,1497	0,1581	0,3228		
<b>R<sup>2</sup></b>	0,9714	0,9348	0,8620		
<b>MSE</b>	0,0017	0,0158	0,0323		
<b>RMSE</b>	0,0417	0,1258	0,1797		




Tabelle A.53: Kenngrößen Neuronales Netz (C12\_10)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Lineare Transf.	tanh	BPM	0,5	0,01	10
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,1829	0,1384	0,2706		
$R^2$	0,9651	0,9429	0,8843		
MSE	0,0087	---	---		
RMSE	0,0933	---	---		




Tabelle A.54: Kenngrößen Neuronales Netz (C21\_0)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momententerm $\pi$	
Lineare Transf.	Logistische Funktion	BP	0,5	---	0
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
<b>SSE</b>	0,5596	0,5162	0,5146		
<b>R<sup>2</sup></b>	0,8932	0,7871	0,7800		
<b>MSE</b>	0,0040	0,0081	0,0080		
<b>RMSE</b>	0,0632	0,0898	0,0897		




Tabelle A.55: Kenngrößen Neuronales Netz (C21\_1)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Lineare Transf.	Logistische Funktion	BP	0,5	---	1
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,2319	0,1506	0,1972		
$R^2$	0,9557	0,9379	0,9157		
MSE	0,0017	0,0024	0,0032		
RMSE	0,0410	0,0493	0,0564		






Tabelle A.56: Kenngrößen Neuronales Netz (C21\_5)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momententerm $\pi$	
Lineare Transf.	Logistische Funktion	BP	0,5	---	5
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
<b>SSE</b>	0,1763	0,1983	0,3610		
<b>R<sup>2</sup></b>	0,9663	0,9182	0,8457		
<b>MSE</b>	0,0021	0,0198	0,0361		
<b>RMSE</b>	0,0453	0,1408	0,1900		




Tabelle A.57: Kenngrößen Neuronales Netz (C21\_10)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Lineare Transf.	Logistische Funktion	BP	0,5	---	10
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,1689	0,1488	0,3095		
$R^2$	0,9678	0,9386	0,8677		
MSE	0,0080	---	---		
RMSE	0,0897	---	---		




Tabelle A.58: Kenngrößen Neuronales Netz (C22\_0)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Lineare Transf.	Logistische Funktion	BPM	0,5	0,1	0
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
<b>SSE</b>	0,6344	0,6687	0,5916		
<b>R<sup>2</sup></b>	0,8789	0,7242	0,7471		
<b>MSE</b>	0,0045	0,0104	0,0092		
<b>RMSE</b>	0,0673	0,1022	0,0961		




Tabelle A.59: Kenngrößen Neuronales Netz (C22\_1)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Lineare Transf.	Logistische Funktion	BPM	0,5	0,1	1
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,2294	0,2129	0,2367		
$R^2$	0,9562	0,9122	0,8988		
MSE	0,0017	0,0034	0,0038		
RMSE	0,0408	0,0586	0,0618		




Tabelle A.60: Kenngrößen Neuronales Netz (C22\_5)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momententerm $\pi$	
Lineare Transf.	Logistische Funktion	BPM	0,5	0,1	5
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
<b>SSE</b>	0,1558	0,1804	0,3267		
<b>R<sup>2</sup></b>	0,9703	0,9256	0,8604		
<b>MSE</b>	0,0018	0,0180	0,0327		
<b>RMSE</b>	0,0426	0,1343	0,1807		




Tabelle A.61: Kenngrößen Neuronales Netz (C22\_10)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Lineare Transf.	Logistische Funktion	BPM	0,5	0,1	10
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,1817	0,1473	0,2775		
$R^2$	0,9653	0,9392	0,8814		
MSE	0,0087	---	---		
RMSE	0,0930	---	---		




Tabelle A.62: Kenngrößen Neuronales Netz (D11\_0)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Standardisierung	tanh	BP	0,2	---	0
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
<b>SSE</b>	0,6267	0,7498	0,7680		
<b>R<sup>2</sup></b>	0,8803	0,6907	0,6717		
<b>MSE</b>	0,0045	0,0117	0,0120		
<b>RMSE</b>	0,0669	0,1082	0,1095		




Tabelle A.63: Kenngrößen Neuronales Netz (D11\_1)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Standardisierung	tanh	BP	0,2	---	1
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,4064	0,8192	0,5712		
$R^2$	0,9224	0,6621	0,7558		
MSE	0,0029	0,0132	0,0092		
RMSE	0,0543	0,1149	0,0960		






Tabelle A.64: Kenngrößen Neuronales Netz (D11\_5)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Standardisierung	tanh	BP	0,2	---	5
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
<b>SSE</b>	0,0253	0,2583	0,5931		
<b>R<sup>2</sup></b>	0,9952	0,8934	0,7465		
<b>MSE</b>	0,0003	0,0258	0,0593		
<b>RMSE</b>	0,0171	0,1607	0,2435		




Tabelle A.65: Kenngrößen Neuronales Netz (D11\_10)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Standardisierung	tanh	BP	0,2	---	10
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,0329	0,1073	0,3433		
$R^2$	0,9937	0,9557	0,8532		
MSE	0,0016	---	---		
RMSE	0,0396	---	---		




Tabelle A.66: Kenngrößen Neuronales Netz (D12\_0)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momententerm $\pi$	
Standardisierung	tanh	BPM	0,2	0,01	0
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
<b>SSE</b>	0,5910	0,8306	0,8809		
<b>R<sup>2</sup></b>	0,8872	0,6574	0,6235		
<b>MSE</b>	0,0042	0,0130	0,0138		
<b>RMSE</b>	0,0650	0,1139	0,1173		




Tabelle A.67: Kenngrößen Neuronales Netz (D12\_1)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Standardisierung	tanh	BPM	0,2	0,01	1
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,6338	0,6741	0,5517		
$R^2$	0,8790	0,7220	0,7642		
MSE	0,0046	0,0109	0,0089		
RMSE	0,0678	0,1043	0,0943		




Tabelle A.68: Kenngrößen Neuronales Netz (D12\_5)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Standardisierung	tanh	BPM	0,2	0,01	5
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,0354	0,2709	0,2787		
$R^2$	0,9932	0,8883	0,8809		
MSE	0,0004	0,0271	0,0279		
RMSE	0,0203	0,1646	0,1669		




Tabelle A.69: Kenngrößen Neuronales Netz (D12\_10)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Standardisierung	tanh	BPM	0,2	0,01	10
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,0252	0,2577	0,1532		
$R^2$	0,9952	0,8937	0,9345		
MSE	0,0012	---	---		
RMSE	0,0347	---	---		




Tabelle A.70: Kenngrößen Neuronales Netz (D21\_0)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Standardisierung	Tanh	BP	0,2	---	0
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
<b>SSE</b>	0,6267	0,7498	0,7680		
<b>R<sup>2</sup></b>	0,8803	0,6907	0,6717		
<b>MSE</b>	0,0045	0,0117	0,0120		
<b>RMSE</b>	0,0669	0,1082	0,1095		




Tabelle A.71: Kenngrößen Neuronales Netz (D21\_1)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Standardisierung	Logistische Funktion	BP	0,2	---	1
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,5285	0,5445	0,5594		
$R^2$	0,8991	0,7754	0,7609		
MSE	0,0038	0,0088	0,0090		
RMSE	0,0619	0,0937	0,0950		






Tabelle A.72: Kenngrößen Neuronales Netz (D21\_5)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Standardisierung	Logistische Funktion	BP	0,2	---	5
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
<b>SSE</b>	0,0491	0,3304	0,1449		
<b>R<sup>2</sup></b>	0,9906	0,8637	0,9380		
<b>MSE</b>	0,0006	0,0330	0,0145		
<b>RMSE</b>	0,0239	0,1818	0,1204		




Tabelle A.73: Kenngrößen Neuronales Netz (D21\_10)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Standardisierung	Logistische Funktion	BP	0,2	---	10
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,0350	0,0826	0,5918		
$R^2$	0,9933	0,9659	0,7470		
MSE	0,0017	---	---		
RMSE	0,0408	---	---		




Tabelle A.74: Kenngrößen Neuronales Netz (D22\_0)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Standardisierung	tanh	BPM	0,2	0,01	0
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
<b>SSE</b>	0,5910	0,8306	0,8809		
<b>R<sup>2</sup></b>	0,8872	0,6574	0,6235		
<b>MSE</b>	0,0042	0,0130	0,0138		
<b>RMSE</b>	0,0650	0,1139	0,1173		




Tabelle A.75: Kenngrößen Neuronales Netz (D22\_1)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Standardisierung	Logistische Funktion	BPM	0,2	0,01	1
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,4721	0,5485	0,5604		
$R^2$	0,9098	0,7738	0,7605		
MSE	0,0034	0,0088	0,0090		
RMSE	0,0585	0,0941	0,0951		




Tabelle A.76: Kenngrößen Neuronales Netz (D22\_5)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Standardisierung	Logistische Funktion	BPM	0,2	0,01	5
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
<b>SSE</b>	0,0440	0,2789	0,1902		
<b>R<sup>2</sup></b>	0,9916	0,8849	0,9187		
<b>MSE</b>	0,0005	0,0279	0,0190		
<b>RMSE</b>	0,0226	0,1670	0,1379		




Tabelle A.77: Kenngrößen Neuronales Netz (D22\_10)

Daten-Transformation	Aktivierungsfunktion VN	Lernverfahren			Anzahl VN
		Verfahren	Lernrate $\eta$	Momentumterm $\pi$	
Standardisierung	Logistische Funktion	BPM	0,2	0,01	10
Gütemaße	Trainingsdaten	Validierungsdaten	Testdaten		
SSE	0,0349	0,1090	0,5139		
$R^2$	0,9933	0,9550	0,7803		
MSE	0,0017	---	---		
RMSE	0,0407	---	---		

