

**ANALYSE UND PROGNOSE VON  
TRAININGSWIRKUNGEN.  
MULTIVARIATE ZEITREIHENANALYSE MIT  
KÜNSTLICHEN NEURONALEN NETZEN**

**Dissertation**

von der Fakultät für Wirtschafts- und Sozialwissenschaften  
der Universität Stuttgart  
zur Erlangung der Würde eines  
Doktors der Philosophie (Dr. phil.) genehmigte Abhandlung

vorgelegt von

**Benjamin Haar**

aus Kirchheim/Teck

Hauptberichter: Prof. Dr. Wilfried Alt

Mitberichter: Prof. Dr. Jürgen Edelmann-Nusser

Tag der mündlichen Prüfung: 28. November 2011

Universität Stuttgart

Institut für Sport- und Bewegungswissenschaft

Stuttgart, 2011

# Inhaltsverzeichnis

<b>Abbildungsverzeichnis</b>	<b>V</b>
<b>Tabellenverzeichnis</b>	<b>VII</b>
<b>Abkürzungsverzeichnis</b>	<b>VIII</b>
<b>Zusammenfassung</b>	<b>IX</b>
<b>Abstract</b>	<b>XI</b>
<b>1 Einleitung</b>	<b>1</b>
<b>2 Forschungsstand</b>	<b>3</b>
2.1 Vorbemerkungen zur Komplexität und Modellbildung in der Trainingswissenschaft . . .	3
2.2 Steuerung von Trainingsprozessen . . . . .	8
2.2.1 Modelle der Leistungsveränderung . . . . .	9
2.2.2 Kybernetische Betrachtungsweise des Trainings . . . . .	12
2.2.3 Synergetische Betrachtungsweise des Trainings . . . . .	13
2.2.4 Trainingsdiagnostik . . . . .	18
2.2.4.1 Trainingskontrolle . . . . .	19
2.2.4.2 Trainingsauswertung . . . . .	22
2.3 Zeitreihenanalyse und -prognose . . . . .	23
2.3.1 Zeitreihenanalyse . . . . .	23
2.3.2 Zeitreihenprognose . . . . .	27
2.4 Modelle zur Analyse und Prognose von Trainingswirkungen . . . . .	29
2.4.1 Antagonistische Trainings-Wirkungs-Modelle . . . . .	29
2.4.1.1 Fitness-Fatigue-Modell . . . . .	30
2.4.1.2 Performance Potential Modell (PerPot-Modell) . . . . .	35
2.4.2 Modellierung von Trainingswirkungen mit neuronalen Netzen . . . . .	39
2.4.3 Alternative Ansätze zur Modellierung von Trainingswirkungen . . . . .	41
2.4.4 Vergleich der Trainings-Wirkungs-Modelle . . . . .	42
2.5 Künstliche neuronale Netze als alternative Methode zur Analyse und Prognose von Zeitreihen . . . . .	47

2.5.1	Das künstliche Neuron als Entscheidungseinheit . . . . .	48
2.5.2	Künstliche neuronale Netze . . . . .	49
2.5.3	Anwendung künstlicher neuronaler Netze zur Analyse- und Prognose von Zeitreihen . . . . .	55
2.5.4	Topologie künstlicher neuronaler Netze zur Analyse und Prognose von Zeitreihen	57
2.5.5	Kritische Analyse der Prognoseleistung künstlicher neuronaler Netze . . . . .	58
<b>3</b>	<b>Problem- und Fragestellung</b>	<b>60</b>
<b>4</b>	<b>Material und Methoden der empirischen Einzelfallanalysen</b>	<b>63</b>
4.1	Forschungszugang und Studiendesign . . . . .	63
4.2	Probandenstichprobe . . . . .	64
4.3	Untersuchungsmethoden . . . . .	65
4.3.1	Trainingsprotokollierung . . . . .	65
4.3.2	Psychologische Erholungs- und Beanspruchungsdiagnostik . . . . .	66
4.3.3	Leistungsdiagnostik . . . . .	67
4.4	Methoden der Verlaufsanalyse . . . . .	69
4.5	Methoden der Analyse und Prognose von Trainingswirkungen . . . . .	70
4.5.1	Multivariate Zeitreihenanalyse mit künstlichen neuronalen Netzen . . . . .	70
4.5.2	Fitness-Fatigue-Modell . . . . .	73
4.5.3	Performance Potential Modell . . . . .	74
4.6	Methodendiskussion . . . . .	75
4.6.1	Studiendesign, Forschungszugang und Probandenstichprobe . . . . .	75
4.6.2	Verfahren der empirische Einzelfallanalysen . . . . .	75
4.6.3	Methoden der Analyse und Prognose von Trainingswirkungen . . . . .	77
<b>5</b>	<b>Ergebnisse</b>	<b>80</b>
5.1	Inspektive Verlaufsanalyse der Untersuchungsergebnisse . . . . .	80
5.1.1	Trainingsprotokollierung . . . . .	81
5.1.2	Psychologische Erholungs- und Beanspruchungsdiagnostik . . . . .	83
5.1.3	Leistungsdiagnostik . . . . .	85
5.2	Empirische Modellprüfung . . . . .	88
5.2.1	Modellanpassung und -prüfung . . . . .	88
5.2.2	Modellvergleich . . . . .	93
<b>6</b>	<b>Diskussion</b>	<b>98</b>
6.1	Empirische Einzelfallanalysen . . . . .	98
6.2	Empirische Modellprüfung . . . . .	99
6.3	Modellvergleich . . . . .	101

<b>7 Zusammenfassung und Ausblick</b>	<b>104</b>
<b>Literatur</b>	<b>106</b>
Literatur . . . . .	106
<b>A Erholungs-Belastungs-Fragebogen (EBF-Sport)</b>	<b>115</b>
<b>B Wertetabellen</b>	<b>119</b>
<b>C Studieninformation, Einverständniserklärung und Datenschutzpassus</b>	<b>123</b>
<b>Lebenslauf</b>	<b>127</b>
<b>Erklärung</b>	<b>128</b>
<b>Danksagung</b>	<b>129</b>

# Abbildungsverzeichnis

2.1	Kennzeichen komplexer Probleme . . . . .	4
2.2	Arbeitsschritte der Modellbildung . . . . .	6
2.3	Prozess wissenschaftlichen Arbeitens . . . . .	7
2.4	Schema der Trainingssteuerung . . . . .	8
2.5	Belastungs-Beanspruchungs-Modell . . . . .	10
2.6	Systemmodell der sportlichen Leistungsfähigkeit . . . . .	12
2.7	Regelkreismodell der kybernetische Betrachtungsweise des Trainings . . . . .	13
2.8	Bifurkationsdiagramm . . . . .	16
2.9	Systemdynamisches Modell des Trainings . . . . .	17
2.10	Trainingsdiagnostik . . . . .	19
2.11	Berechnung des Trainingsimpulses . . . . .	21
2.12	Einzelfallbezogene Trainings- und Leistungsverlaufsanalyse . . . . .	22
2.13	Einzelfallbezogene Trainingswirkungsanalyse . . . . .	23
2.14	Fitness-Fatigue-Modell . . . . .	30
2.15	Performance Potential Modell . . . . .	36
2.16	Trainings-Wirkungs-Modell auf der Basis neuronaler Netze . . . . .	40
2.17	Schema und Informationsverarbeitung eines künstlichen Neurons . . . . .	48
2.18	Logistische und tanh-Aktivierungsfunktion . . . . .	49
2.19	Das neuronale Netz als Entscheidungsstruktur . . . . .	50
2.20	Entwicklung eines künstlichen neuronalen Netzes . . . . .	54
2.21	Vertikale Prognose von Zeitreihen mit künstlichen neuronalen Netzen . . . . .	56
2.22	Vertikale und horizontale und Prognose von Zeitreihen mit künstlichen neuronalen Netzen . . . . .	57
3.1	Grundlegende Modellstruktur . . . . .	61
4.1	Studiendesign und Zeitplan . . . . .	64
4.2	Beispielitem und Antwortmodus des EBF-Sport . . . . .	66
4.3	Versuchsaufbau Spiroergometrie . . . . .	67
4.4	Belastungsprotokoll der Spiroergometrie . . . . .	68
4.5	Phasenplot einer fiktiven Zeitreihe . . . . .	69

4.6	Struktur des künstlichen neuronalen Netzes zur Analyse und Prognose von Trainingswirkungen . . . . .	71
4.7	Netzwerktopologie bei reduzierter Modellkomplexität . . . . .	73
5.1	Kategoriale Trainingsprotokollierung Proband 1 . . . . .	81
5.2	Kategoriale Trainingsprotokollierung Proband 2 . . . . .	82
5.3	Kategoriale Trainingsprotokollierung Proband 3 . . . . .	82
5.4	Psychologische Erholungs- und Beanspruchungsdiagnostik Proband P1 . . . . .	83
5.5	Psychologische Erholungs- und Beanspruchungsdiagnostik Proband P2 . . . . .	84
5.6	Psychologische Erholungs- und Beanspruchungsdiagnostik Proband P3 . . . . .	84
5.7	Leistungsdiagnostik Proband P1 . . . . .	85
5.8	Leistungsdiagnostik Proband P2 . . . . .	86
5.9	Leistungsdiagnostik Proband P3 . . . . .	86
5.10	Phasenplot Leistungsverlauf Proband P1 . . . . .	87
5.11	Phasenplot Leistungsverlauf Proband P2 . . . . .	87
5.12	Phasenplot Leistungsverlauf Proband P3 . . . . .	88
5.13	Ergebnis der KNN-Modellierung für Proband P1 . . . . .	89
5.14	Ergebnis der KNN-Modellierung für Proband P2 . . . . .	91
5.15	Ergebnis der KNN-Modellierung für Proband P3 . . . . .	92
5.16	Ergebnis der FF-Modellierung Proband P1 . . . . .	94
5.17	Ergebnis der FF-Modellierung Proband P2 . . . . .	94
5.18	Ergebnis der FF-Modellierung Proband P3 . . . . .	95
5.19	Ergebnis der PerPot-Modellierung Proband P1 . . . . .	96
5.20	Ergebnis der PerPot-Modellierung Proband P2 . . . . .	97
5.21	Ergebnis der PerPot-Modellierung Proband P3 . . . . .	97
C.1	Studieninformation . . . . .	124
C.2	Einverständniserklärung . . . . .	125
C.3	Datenschutzpassus . . . . .	126

# Tabellenverzeichnis

2.1	Zeitreihenanalyse	26
2.2	Eigenschaften von Trainings-Wirkungs-Modellen	46
4.1	Anthropometrische Daten der Versuchspersonen	65
4.2	Merkmale der Netzwerktopologie und Trainingsparameter	72
4.3	Startwerte und Wertebereich der Modellparameter des FF-Modells	74
4.4	Validierung der künstlichen neuronalen Netze zur Analyse und Prognose von Trainingswirkungen	78
5.1	Mittelwerte und Standardabweichungen der Trainings-, Erholungs-Beanspruchungs- und Leistungsdaten	80
5.2	Modellparameter, Modellgüte und Prognoseleistung der simulativen Trainingswirkungsanalyse mit dem KNN-Modell Proband P1	89
5.3	Modellparameter, Modellgüte und Prognoseleistung der simulativen Trainingswirkungsanalyse mit dem KNN-Modell Proband P2	90
5.4	Modellparameter, Modellgüte und Prognoseleistung der simulativen Trainingswirkungsanalyse mit dem KNN-Modell Proband P3	91
5.5	Modellgüte und Prognoseleistung bei reduzierter Modellkomplexität	93
5.6	Modellparameter, Modellgüte und Prognoseleistung der simulativen Trainingswirkungsanalyse mit dem FF-Modell	93
5.7	Modellparameter, Modellgüte und Prognoseleistung der simulativen Trainingswirkungsanalyse mit dem PerPot-Modell	96
A.1	EBF-Sport	115
A.1	EBF-Sport	116
A.1	EBF-Sport	117
A.2	Auswertung EBF-Sport	118
B.1	Datentabelle Proband P1	120
B.2	Datentabelle Proband P2	121
B.3	Datentabelle Proband P3	122

## Abkürzungsverzeichnis

BPM	Backpropagation mit Momentum
bspw.	beispielsweise
bzw.	beziehungsweise
cm	Zentimeter
DGSP	Deutsche Gesellschaft für Sportmedizin
ebd.	ebenda
EBB	Erholungs-Beanspruchungs-Bilanz
EBF	Erholungs-Belastungs-Fragebogen
EKG	Elektrokardiogramm
et al.	et alii (und andere)
FF-Modell	Fitness-Fatigue-Modell
GEW	Gesamterholungswert
GBW	Gesamtbelastungswert
HF	Herzfrequenz
kg	Kilogramm
KNN	künstliche neuronale Netze
KNN-Modell	künstliche neuronale Netze Modell
LF	Leistungsfähigkeit
min	Minute
MLP	Multi Layer Perceptron
MSE	mean square error
PC	Personal-Computer
PerPot-Modell	Performance-Potential-Modell
POMS	Profile of Mood State
$r^2$	Determinationskoeffizient
RMSE	root mean square error
RPROP	Resilient Propagation
SimBEA-Modell	Modell zur Simulation von Belastungs-, Ermüdungs- und Anpassungsprozessen
TD	Trainingsdaten
TRIMP	Trainingsimpuls
u.a.	unter anderem
u.U.	unter Umständen
vgl.	vergleiche
VO <sub>2</sub> max	maximale Sauerstoffaufnahme
z.B.	zum Beispiel



# Zusammenfassung

## Einleitung

Modelle zur Analyse und Prognose von Trainingswirkungen sind vielversprechende Verfahren für eine individuelle Optimierung der Belastungsgestaltung. Die starken Vereinfachungen der antagonistischen und non-parametrischen Modelle führen aber zu einer geringen Modellgüte und Prognoseleistung. Forschungsbedarf besteht daher hinsichtlich neuer multifaktorieller Modelle, die den komplexen und dynamischen Trainingsprozess hinreichend abbilden.

Künstliche neuronale Netze (KNN) haben sich als Methode zur Analyse und Prognose von nichtlinearem und dynamischem Systemverhalten bewährt. Das Ziel dieser Arbeit ist es, den Zusammenhang zwischen Beanspruchung und sportlicher Leistungsfähigkeit mit KNN verlaufsorientiert abzubilden und die Leistungsentwicklung vorherzusagen.

## Material und Methoden

An dieser Studie nahmen drei hochtrainierte Triathleten teil ( $27 \pm 10$  Jahre;  $VO_2\max = 3,72 \pm 0,15$  l·min<sup>-1</sup>). Während des dreimonatigen Untersuchungszeitraums wurde täglich die Trainingsbeanspruchung in vier Kategorien (Laufen, Radfahren, Schwimmen und Krafttraining) anhand der Herzfrequenz und des zeitlichen Umfangs dokumentiert. Die Erholungs-Beanspruchungsbilanz der Athleten wurde jeden dritten Tag an 30 Messzeitpunkten mit einem Fragebogen erfasst. Die maximale Sauerstoffaufnahme wurde als Maß für die Ausdauerleistungsfähigkeit ebenfalls alle drei Tage mit einer Fahrrad-Spiroergometrie bestimmt.

Für die multivariate Zeitreihenanalyse wurde ein Backpropagation-Netz eingesetzt. Die Trainingsbeanspruchung und der psychometrisch erfasste Erholungs- und Beanspruchungszustand wurden als Prädiktorvariablen berücksichtigt. Die Dynamik des Trainingsprozesses wurde über den Zusammenhang zwischen der Leistungsfähigkeit und der Leistungsentwicklung abgebildet. Die KNN wurden für jeden Athleten mit 24 Datensätzen trainiert. Die Entwicklung der Leistungsfähigkeit wurde über vier Messzeitpunkte vorhergesagt.

Durch eine schrittweise Reduktion der Eingabedaten, wurde das multivariate Modellkonzept auf seine Gültigkeit hin geprüft. Die Modellgüte und Prognoseleistung wurden im Vergleich zu den antagonistischen Modellen bewertet.

## Ergebnisse

Bei allen Probanden wird bei der Analyse und Prognose von Trainingswirkungen mit KNN (KNN-Modell) eine hohe Modellgüte (root mean square error (RMSE) =  $0,05 \pm 0,02 \text{ l}\cdot\text{min}^{-1}$ ) und Vorhersagegenauigkeit (RMSE =  $0,08 \pm 0,03 \text{ l}\cdot\text{min}^{-1}$ ) erreicht. Die Reduktion der Eingabedaten führt zu einer abnehmenden Abbildungs- und Prognoseleistung. Die Modellgüte und Prognoseleistung des KNN-Modells ist im Vergleich zu den antagonistischen Trainings-Wirkungs-Modellen höher.

## Diskussion

KNN sind besonders zur verlaufsorientierten Analyse und Prognose von Trainingswirkungen geeignet. Der Vorteil dieser Methode ist in der multivariaten Modellstruktur zu sehen. Durch die differenzierte Berücksichtigung trainingsinduzierter Beanspruchungen und des aktuellen Erholungs- und Beanspruchungszustands wird ein höherer Erklärungswert für die Leistungsentwicklung erreicht. Trainings-Wirkungs-Modelle mit geringerer Komplexität bilden den Leistungsverlauf nur ungenau ab und können die Leistungsentwicklung nicht exakt vorhersagen.

## Schlussfolgerung

Simulative Trainings-Wirkungs-Modelle eignen sich für eine individuelle Trainingssteuerung nur dann, wenn sie in hohem Maße die Komplexität und Dynamik des Trainingsprozesses abbilden. Dann bietet sich aber ein praktischer Einsatz vor allem in der kurzfristigen Trainingsplanung oder Wettkampfvorbereitung an.

# Abstract

## Introduction

Models for analysis and prediction of training effects are encouraging methods for an individual improvement to organize the training loads. The keen simplifications of antagonistic and non-parametric models, however, lead to a weaker model quality and prognostic results. There is research need for new multifactorial models that can sufficiently represent the complex and dynamic training process. Artificial neuronal networks (ANN) have proved themselves as methods for analysis and prediction of nonlinear and dynamic systems. The purpose of this study is to analyze the relationship between strain and performance with the help of ANN and to give a prediction concerning the development of performance.

## Material and Methods

Three highly-trained triathletes participated in this study (age  $27 \pm 10$ ;  $VO_{2max} = 3,72 \pm 0,15$  l·min<sup>-1</sup>). Daily training amounts in four categories (running, cycling, swimming and strength training) were recorded by means of heart rate and training duration during the three-month period of examination. Stress and recovery assessment was done by a questionnaire every third day for 30 measurements. Maximum oxygen uptake was also measured for endurance performance every third day by means of cycle spiroergometry.

A back propagation net was used for multivariate time series analysis. Training strain and the psychometrically documented stress-recovery state were considered as predictors. The dynamic of the training process was represented by the relationship between performance and the development of performance. The ANN was trained for each athlete with 24 data sets. The development of performance was predicted over a period of four measure times.

Because of a gradual input data reduction, the multivariate model concept has been proved concerning its validity. The model quality and the prognostic results have been evaluated in comparison with the antagonistic models.

## Results

Concerning all the test persons, the analysis (root mean square error (RMSE) =  $0,05 \pm 0,02 \text{ l}\cdot\text{min}^{-1}$ ) and prediction (RMSE =  $0,08 \pm 0,03 \text{ l}\cdot\text{min}^{-1}$ ) of training effects with ANN have reached a high model quality and exactness in prediction. The input data reduction has led to a decreasing performance and prognosis efficiency. There is a higher model quality and prediction efficiency of the ANN in comparison with the antagonistic training effect models.

## Discussion

Artificial neuronal networks are especially qualified for process oriented analysis and prediction of training effects. The advance of this method can be seen in the multivariate model structure. Based on the sophisticated consideration of training induced strain and based on the actual recovery and stress state, there can be reached a higher degree of explanation for the development of performance. Models for analysis and prediction of training effects with less complexity reproduce changes in performance inexactly and they cannot predict the development of performance accurately.

## Conclusion

Models for analysis and prediction of training effects are only suitable for an individual training program design when they represent the complexity and dynamic of the training process in a high level. According to this aspect, these models are practical for an applied charge particularly for short term training programs or for an intensively preparation for the next competition.

# Kapitel 1

## Einleitung

Der Spitzensport ist zunehmend durch eine höhere Leistungs- und Wettkampfdichte gekennzeichnet. Die Aussicht auf sportlichen und damit auch finanziellen Erfolg sowie soziale Anerkennung wird damit immer weniger kalkulierbar. Es sind daher entsprechend hohe Wettkampf- und Trainingsumfänge nötig, um eine nationale und internationale Konkurrenzfähigkeit zu sichern. Gleichzeitig erhöht dies die Anforderungen an geeignete Planungs- und Steuerungsinstrumente zur optimalen Belastungsgestaltung. Hierfür haben sich Modelle zur Analyse und Prognose von Trainingswirkungen als vielversprechend erwiesen (vgl. u.a. Banister, Calvert, Savage & Bach, 1975; Mester & Perl, 2000; Hohmann, Edelmann-Nusser & Henneberg, 2000; Ganter, Witte & Edelmann-Nusser, 2006; Brückner & Wilhelm, 2008). Solche Verfahren sind aber nicht nur für die Steuerung des Trainings im Spitzensport interessant. Sie können bereits von ambitionierten Freizeitsportler mit einer kommerziellen Software für die individuelle Trainingsoptimierung eingesetzt werden (WKO+, TrainingPeaks<sup>TM</sup>, Lafayette, USA).

Obwohl zunehmend Arbeiten zu simulativen Trainings-Wirkungs-Modellen veröffentlicht werden und die Möglichkeiten der trainingspraktischen Nutzung zunehmen, bestehen immer noch methodische Limitierungen. Busso & Thomas (2006, S. 404) fassen die wesentlichen Schwierigkeiten zusammen, die vor allem für die antagonistischen Modelle gelten (Banister, Calvert, Savage & Bach, 1975; Mester & Perl, 2000):

„In any case, it is likely that the expected accuracy between model prediction and actual data will greatly suffer from simplifications made to aggregate total training strain in a single variable and, more generally, from the abstraction of complex physiological processes into a very small number of entities. If the intended purpose is to develop an instrument to help a coach prescribe a training program for a particular athlete, new modeling strategies should be considered in accordance with the specificity of the activity.“

Dieses Zitat verdeutlicht gleichermaßen, dass vor allem die Komplexität des Gegenstands Training für die Probleme im Erkenntnisprozess entscheidend ist. Das betrifft sowohl die eben genannte Methodenentwicklung und -anwendung als auch die theoretischen Modelle des Trainings und der Trainingssteuerung. In der jüngeren Vergangenheit konzentriert sich die Forschung nicht zuletzt wegen

phänomenologischer und trainingspraktischer Erfahrungen vermehrt darauf, mit einer modelltheoretischen und methodischen Annäherung diese Problematik aufzulösen (Hohmann, Edelmann-Nusser & Henneberg, 2000; Mester & Perl, 2000; Hohmann, Lames & Letzelter, 2007; Ganter, 2009).

Die Zielsetzung dieser Arbeit ist es, die eben skizzierte Diskussion aufzugreifen und einen eigenen Beitrag zum besseren Verständnis von Trainingsprozessen und zur Optimierung sportlicher (Spitzen-) Leistung zu liefern. Die Grundlage hierfür ist eine konsequente Weiterentwicklung der synergetischen Betrachtungsweise zu einem eigenen Modell des Trainings. Das Forschungsdefizit ist vor allem in einer mangelnden Verknüpfung von Anpassungsmechanismen und Steuerungsstrategien zu einem ganzheitlichen Ansatz zu sehen.

Eine weitgehend ungenutzte Reserve ist im Angebot an verlaufsorientierten analytischen Verfahren anderer wissenschaftlicher Disziplinen für die Anwendung zur Trainingswirkungsanalyse zu sehen. Entscheidend dabei ist, dass die methodische Umsetzung in Übereinstimmung zu den grundlegenden Modellen des Trainings und nicht zum Selbstzweck einer maximalen Modellgenauigkeit erfolgt. Künstliche neuronale Netze haben sich als Methode zur Analyse und Prognose von nichtlinearem und dynamischem Systemverhalten bewährt. Im Rahmen einer empirischen Untersuchung wird am Beispiel mehrerer Zeitreihenanalysen im Triathlon geprüft, ob sich künstliche neuronale Netze zur multivariaten Trainingswirkungsanalyse eignen und Hinweise ergeben, die das theoretische Konzept eines systemdynamischen Modells des Trainings stützen.

Die vorliegende Arbeit ist in einen theoretischen und einen empirischen Teil gegliedert. Im ersten Kapitel werden Modelle des Trainings und der Trainingssteuerung aufgearbeitet und daraus das eigene theoretische Modell abgeleitet. Daran schließt sich eine Übersicht über individuenzentrierte Forschungsstrategien in der Trainingswissenschaft an. Den Schwerpunkt bildet die Analyse des Forschungsstand zu simulativen Trainings-Wirkungs-Modellen, wobei der Fokus auf einer Diskussion spezifischer Modelleigenschaften und deren Entsprechung zu den Modellen des Trainings liegt. Im letzten Abschnitt werden die theoretischen Grundlagen künstlicher neuronaler Netze und deren Anwendungsmöglichkeiten für die Analyse und Prognose von Zeitreihen dargestellt.

Auf der Basis des vorhandenen Forschungsdefizits wird die Problem- und Fragestellung der Arbeit formuliert. Der empirische Teil beginnt mit einer ausführlichen Beschreibung des methodischen Vorgehens. Dies umfasst die Methodik der empirischen Einzelfallanalysen sowie die verlaufsbezogenen Verfahren der Trainingswirkungsanalyse. Auf der Grundlage der Ergebnisdarstellung werden im letzten Abschnitt die Resultate in Bezug zur Fragestellung und dem aktuellen Stand der Forschung diskutiert.

# Kapitel 2

## Forschungsstand

### 2.1 Vorbemerkungen zur Komplexität und Modellbildung in der Trainingswissenschaft

Das Selbstverständnis der Trainingswissenschaft ist es, aus einer ganzheitlichen und angewandten Perspektive die Gegenstandsbereiche Training, Wettkampf und Leistung wissenschaftlich zu fundieren. D.h. die Trainingswissenschaft stellt der Praxis nomologisches und technologisches Wissen zur Verfügung. Sie versteht sich als empirische Wissenschaft mit einem kritisch-rationalen Forschungsparadigma (Popper, 1971; Hohmann et al., 2007). Ziel ist es daher, den Bewährungsgrad einer Theorie im Rahmen des Erkenntnisprozesses zu erhöhen. Dafür steht der Trainingswissenschaft ein Spektrum an Forschungsstrategien zur Verfügung. Sofern es darum geht, deduktiv handlungsrelevante Wissensbestände abzuleiten, werden die Strategien der Grundlagen- und Anwendungsforschung verfolgt. Beim Transfer von der nomologisch-technologischen Ebene zur Ebene des praktischen Handelns ergeben sich aber bei den genannten Strategien aus wissenschaftstheoretischer und forschungspragmatischer Sicht Restriktionen. Der Übergang vom Wahrheitskriterium nomologischen und nomopragmatischen Wissens auf das Wirksamkeitskriterium technologischer Regeln und des praktischen Handelns stellt einen Kategoriensprung dar, der nicht zulässig ist (Schlicht & Lames, 1993). Solange nicht alle Randbedingungen und die Effizienz anderer Handlungsalternativen auf ihre Wirksamkeit hin beschrieben und geprüft sind, sind solche Ableitungen logisch nicht zu leisten. Aus forschungspragmatischer Perspektive schränken das Stichprobenproblem von Studien im Hochleistungssport und das Kontrollgruppenproblem von experimentellen Studien im Allgemeinen den deduktiven Ansatz zur wissenschaftlichen Fundierung sportpraktischen Handelns weiter ein (Lames, 1999, S. 52 - 53).

Die Trainingswissenschaft versteht sich nicht nur als Erfahrungswissenschaft sondern auch als angewandte Wissenschaft. Sie verfolgt damit keine Doppelorientierung. Die Trainingswissenschaft deckt die unterschiedlichen Ausrichtungen mit ihrem Spektrum an Forschungsstrategien ab. Die Evaluationsforschung sichert die Praxisrelevanz wissenschaftlicher Befunde. Dies stellt einen Perspektivenwechsel dar, da es nicht mehr nur darum geht, Theorien deduktiv zu prüfen sondern induktiv die Praxis

selbst mit dem Ziel der Theoriebildung zu untersuchen. „Die Evaluationsforschung ist die systematische Anwendung wissenschaftlicher Methoden zur Bewertung des Konzepts, der Implementation, der Wirksamkeit und der Effektivität einer Intervention“ (Rossi & Freeman, 1993). Ziel der trainingswissenschaftlichen Evaluationsforschung ist es, in einem induktiven Erkenntnisgewinn systematisch Erfahrungen aus praktischen Interventionen zu einem praxisrelevanten Wissensbestand zu verdichten. Damit wird deutlich, dass die Evaluationsforschung eine komplementäre Forschungsstrategie zur Grundlagen- und Anwendungsforschung darstellt (Hohmann et al., 2007).

Die Aufgabe der Trainingswissenschaft ist es also, aus empirischer und angewandter Perspektive Veränderungswissen für das praktische Handeln im Sport zu generieren. Mit der Öffnung des Trainingsbegriffs reicht das Spektrum von der Ansteuerung biologischer Anpassungsprozesse bis hin zu sozialen Interventionen (Ballreich & Kuhlow, 1975; Schnabel, Harre, Krug & Borde, 2005; Hohmann et al., 2007). Im Zentrum dieser Trainingsprozesse steht der Athlet als „biopsychosoziale Einheit“ (Schnabel et al., 2005, S. 27). Dabei muss aber bereits auf einer mikroskopischen Betrachtungsebene von komplexen Prozessen bei der Regulation von Körperfunktionen ausgegangen werden (Gerok, 1990). Auf makroskopischer Ebene ist zu beobachten, dass Trainingsanpassungen nicht nach einem einfachen, linearen Reiz-Reaktions-Schema ablaufen, sondern das System selbst verändern (Foerster, 1988). Man muss von höchst individuellen Vorgängen ausgehen, die von vielen teils unbestimmten inneren und äußeren Bedingungen und Einflüssen abhängen. Witte (2002, S. 16) beschreibt in diesem Zusammenhang den Menschen als „ein komplexes System mit einer inneren nichtlinearen Dynamik“.



Abbildung 2.1: Kennzeichen komplexer Probleme (mod. nach Hasselmann, 1993, S. 37).

Die Anforderungen und die Komplexität nehmen weiter zu, wenn es um die Steuerung des gesamten



Trainingsprozesses geht. Brack (2002) konnte ursprünglich zeigen, dass die Merkmale komplexer Probleme nach Dörner et al. (1983, S. 19 - 26) das Training in Sportspielen kennzeichnen (vgl. Abbildung 2.1). Diese systematische Betrachtung der Komplexitätsproblematik lässt sich aber auf den gesamten Gegenstandsbereich Training übertragen.

Damit wird deutlich, dass die wissenschaftliche Rekonstruktion der Realität neben dem bereits genannten Stichproben- und Kontrollgruppenproblem zusätzlich durch die Komplexität des Gegenstands bestimmt ist. Ein forschungsmethodischer Zugang ist nur mit einer geeigneten Modellbildung zur Reduktion der Komplexität möglich. Dazu gehören bspw. Leistungsstrukturmodelle, Modelle des Trainings oder Modelle der Trainingssteuerung (vgl. Hohmann et al., 2007). In jüngerer Zeit gewinnt die Modellierung von Trainingswirkungen zunehmend an Bedeutung (vgl. Kapitel 2.4) und bildet auch den Rahmen für diese Arbeit.

Stachowiak (1973) hat mit seiner Erkenntnislehre einen wissenschaftstheoretischen Gesamtentwurf entwickelt, der neben einer Systematisierung von Modelltypen und -eigenschaften einen grundlegenden Entwurf hypothetisch deduktiven Erkennens einschließt. In der Sportwissenschaft hat Ballreich (1988) erstmals die allgemeine Modelltheorie Stachowiaks aufgegriffen und deren Wert für die Biomechanik beschrieben. Lames (2002, S. 187) betont jedoch, dass sich die Umsetzung in der Sportwissenschaft meist auf eine modellbildnerisch-praktische Ebene beschränkt. Erkenntnistheoretische Implikationen wurden bisher nicht herausgearbeitet.

Die zentrale Annahme des Modellkonzepts besteht darin, dass „alle Erkenntnis *Erkenntnis in Modellen* oder *durch Modelle*“ ist (Stachowiak, 1973, S. 56). Damit ergibt sich die prinzipielle Prämisse, jeglichen Erkenntnisgewinn an Modellen vorzunehmen, da selbst die einfachste Struktur nicht vollständig erfasst werden kann. Der allgemeine Modellbegriff nach Stachowiak (1973) ist durch drei Hauptmerkmale gekennzeichnet:

**Abbildungsmerkmal** „*Modelle sind stets Modelle von etwas, nämlich Abbildungen, Repräsentationen natürlicher oder künstlicher Originale, die selbst wiederum Modelle sein können*“ (Stachowiak, 1973, S. 131). Das Abbildungsmerkmal sichert die Zuordnung von Modell-Attributen zu Attributen des Modelloriginals. Diese Ähnlichkeit ermöglicht einen Analogieschluss von bekannten Modelleigenschaften auf unbekannte Eigenschaften des Originals.

**Verkürzungsmerkmal** „*Modelle erfassen im allgemeinen nicht alle Attribute des durch sie repräsentierten Originals, sondern nur solche, die den jeweiligen Modellerschaffern und/oder Modellbenutzern relevant scheinen*“ (ebd., S. 132). Das Verkürzungsmerkmal ist das zentrale Wesen eines Modells. Modelle sind vereinfachte, abstrakte Abbilder eines Systems.

**Pragmatisches Merkmal** „*Modelle sind ihren Originalen nicht per se eindeutig zugeordnet. Sie erfüllen ihre Ersatzfunktion a) für bestimmte - erkennende und/oder handelnde, modellbenutzende - Subjekte, b) innerhalb bestimmter Zeitintervalle und c) unter Einschränkung auf bestimmte gedankliche oder tatsächliche Operationen*“ (ebd., S. 132 - 133). Das pragmatische oder


Subjektivierungsmerkmale kennzeichnet die Eigenschaft, dass die Ersatzfunktion eines Modells (Originalbezug) immer unter den Einschränkungen des Benutzer-, Zeit- und Zweckbezugs zu betrachten ist.

Stachowiak (1973, S. 138 - 139) nennt unterschiedliche Gründe, warum Modelle zur Originalrepräsentation herangezogen werden. Daraus ergeben sich vier unterschiedliche Modelltypen:

1. Demonstrationsmodell zur Veranschaulichung komplizierter Zusammenhänge,
2. Experimentalmodell zur Ermittlung und Überprüfung von Hypothesen,
3. Theoretisches Modell zur Erkenntnisvermittlung in logisch bündiger Form und
4. Operatives Modell für die Benutzer als Entscheidungs- und Planungshilfe.

Allen Modelltypen gemein ist, wesentliche Grundzusammenhänge darzustellen, diese zu erklären oder damit Vorhersagen zu treffen.

Nach der formalen Definition der Merkmale von Modellen und der Abgrenzung von Modelltypen bleibt zu klären, welcher Original-Modell-Vergleichsmodus geeignet ist. Als Vergleichsmaß ist analog zum testtheoretischen Gütekriterium die inhaltliche und kriterienbezogene Validität des Modells zu bestimmen (Stachowiak, 1973; Ballreich, 1988). Abhängig vom Modelltyp ist die Entscheidung zu treffen, ob der Modellgültigkeit theoretisch-logische Überlegungen oder empirisch-numerische Abbildungsrelationen zugrunde gelegt werden.

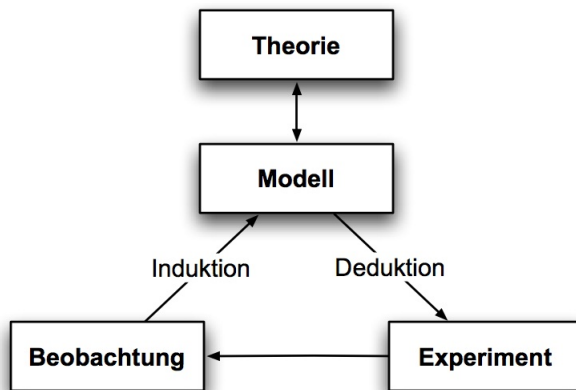


**Abbildung 2.2:** Allgemeines Schema der Arbeitsschritte einer Modellbildung (mod. nach Ballreich, 1988, S. 113).

Für die Modellierung in der Biomechanik hat Ballreich (1988, S. 113) „Arbeitsschritte der Modellmethode“ ausführlich beschrieben. Daraus lässt sich ein allgemeines Schema für einen Modellbildungsprozess ableiten (vgl. Abbildung 2.2). Die Modellbildung ist ein iterativer Prozess. In der Problemformulierung werden die pragmatischen Fragen geklärt werden, wovon etwas Modell ist (Originalbezug), wozu es Modell (Zweckbezug) und für wen es Modell ist (Benutzerbezug). Auf deren Grundlage führt die Modellkonstruktion zu einem ersten Modellansatz. Dieser Modell-Prototyp wird im nächsten

Arbeitsschritt auf seine Gültigkeit hin überprüft. Sofern die Modellgüte, d.h. der Grad der Übereinstimmung zwischen Modell und Original, gering ist, sind Revisionen des Modells erforderlich. Ergibt die Modellvalidierung eine positive Übereinstimmung, kann das Modell für die Simulation verwendet werden. Unter einer Simulation ist die Realisation des Modellverhaltens zu verstehen. Die Intention der Modellsimulation liegt darin, „das Verhalten des simulierten Modells und des dadurch modellierten Systems zu prognostizieren“ (Perl & Uthmann, 1997, S. 65).

Die allgemeine Modelltheorie Stachowiaks wurde in der Trainingswissenschaft bisher kaum rezipiert (z.B. Lames, 1991; 1994). Eine interdisziplinäre Behandlung liegt für die Sportwissenschaft von Perl, Lames und Glitsch (2002) vor, wobei das Augenmerk mehr auf dem Nutzen als Erkenntnismethode liegt. Darin ist auch der Wert der für die Trainingswissenschaft im Allgemeinen und für die Problemstellung der vorliegenden Arbeit im Speziellen zu sehen. Wesentlich ist die Einsicht, dass alle Erkenntnis Erkenntnis in Modellen oder durch Modelle ist. Die Komplexität des Gegenstands der Trainingswissenschaft macht es grundsätzlich notwendig, Wissen am Modell zu generieren.

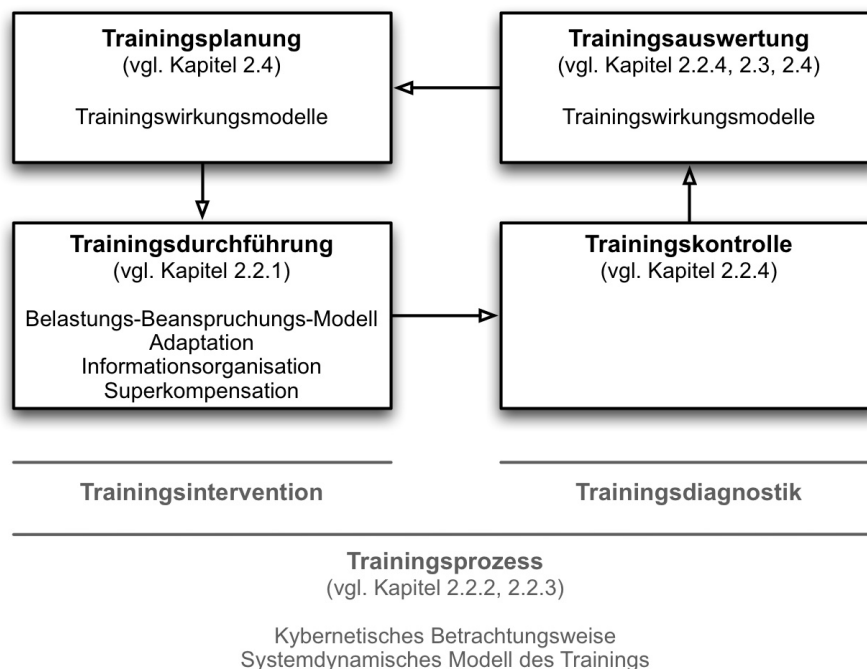


**Abbildung 2.3:** Die Funktion des Modells als Filterebene im Prozess des wissenschaftlichen Arbeitens (mod. nach Glitsch, 2002, S. 110).

Es muss daher keine Diskussion darüber geführt werden, ob sich die Trainingswissenschaft grundsätzlich an einem kritisch-rationalen Forschungsparadigma oder dem Modellismus Stachowiaks orientieren sollte. Beide erkenntnistheoretischen Anschauungen sind mit der forschungsstrategischen Ausrichtung der Trainingswissenschaft vereinbar. Stachowiak lehnt sogar ausdrücklich die Methodenlehre des kritischen Rationalismus nicht ab, sondern lässt neben der falsifizierbarkeitstheoretischen deduktiven Erkenntnisgewinnung auch induktionistische und pragmatische Verfahren der Theorieprüfung zu. Es ist vielmehr der Ansatz von Glitsch (2002, S. 110) zu unterstreichen, auch in der Trainingswissenschaft das Modell als methodische Zwischenstufe im Prozess des wissenschaftlichen Arbeitens anzusehen (vgl. Abbildung 2.3).

## 2.2 Steuerung von Trainingsprozessen

Hohmann et al. (2007, S. 162 - 178) haben einen Vorschlag eingebracht, wie der Trainingsprozess anhand unterschiedlicher Perspektiven strukturiert werden kann. Einer Innenperspektive des Trainings ordnen sie Modelle der Leistungsveränderung durch Adaptation und Informationsorganisation zu. Diese Perspektive wird durch eine Außenperspektive des Trainings ergänzt. Dazu gehören das pädagogisch-didaktische Modell der Trainingssteuerung und die Trainingssteuerung aus kybernetischer Sicht. Die dritte, ganzheitliche Perspektive beschreibt das Training aus synergetischer Sicht. Der Vorteil dieser Gliederung besteht darin, dass aus didaktischen Gründen eine Trennung in Perspektiven zum besseren Verständnis der einzelner Teilprozesse beiträgt. Andererseits führt dies aber dazu, dass durch die getrennte Beschreibung Abhängigkeiten und Funktionszusammenhänge nicht deutlich gemacht werden können.



**Abbildung 2.4:** Allgemeines Schema zur Regelung des Trainingsprozesses (mod. nach Hohmann, 1994, S. 14). Den einzelnen Instanzen sind weitere Modelle des Trainings und der Trainingssteuerung zugeordnet.

Ein adäquates, übergreifendes Modell der Trainingssteuerung wurde von Hohmann (1994) entwickelt. Dieser systemtheoretische Ansatz stellt ein allgemeines Schema zur Regelung eines Trainingsprozesses dar. Hierzu gehören die Instanzen der Trainingsplanung, der Trainingsdurchführung, der Trainingskontrolle und der Trainingsauswertung. Die Trainingssteuerung wird durch dieses Schema als prozessuales Planungsmodell beschrieben, das den Systemcharakter von Training abbildet. Hohmann et al. (2007, S. 172) definieren die Trainingssteuerung als eine „gewichtete kurz-, mittel- und langfristige Abstimmung und Ausführung aller Planungs-, Trainings-, Kontroll- und Lenkungsmaßnahmen eines Trai-


ningsprozesses zur Erreichung der Trainingsziele“. Die Trainingssteuerung im engeren Sinne schließt die Trainingsplanung und -durchführung ein.

Durch seinen hohen Allgemeingrad ist der Regelkreis als Leitfaden für die Steuerung von Trainingsprozessen zu verstehen. In das Ablaufschema lassen sich alle weiteren Modelle zum Training und zur Trainingssteuerung einordnen. Aus der Abbildung 2.4 geht ein eigener Ansatz hervor, wie die Modelle zum Training und zur Trainingssteuerung systematisiert werden können. In den nächsten Abschnitten werden diese Modelle und die Instanzen der Trainingssteuerung ausführlicher beschrieben. Lediglich auf die Trainingsplanung wird nicht näher eingegangen sondern auf die entsprechenden Quellen verwiesen (vgl. Hohmann, 1994; Schnabel et al., 2005; Hohmann et al., 2007; Baechle & Earle, 2008).

### 2.2.1 Modelle der Leistungsveränderung

Die theoretischen Modelle des Trainings oder der Leistungsveränderungen können im o.g. Prozessmodell der Trainingsdurchführung zugeordnet werden. Das integrative Belastungs-Beanspruchungsmodell von Schnabel et al. (2005, S. 58) hat davon die größte Bedeutung erlangt (vgl. Abbildung 2.5). Das Modell entstammt dem arbeitswissenschaftlichen Belastungs-Beanspruchungsparadigma (Rohmert & Rutenfranz, 1975). Das Konzept beruht darauf, dass eine Leistungsveränderung von (objektiven) Belastungen ausgeht, die in Abhängigkeit von unterschiedlichen individuellen Leistungsvoraussetzungen zu einer (subjektiven) Beanspruchung der Funktionssysteme führt. In Anlehnung an die verallgemeinerte Struktur sportlicher Leistung unterscheidet man das energieübertragende (Konstitution), das energiebereitstellende (Kondition), das bewegungsregulierende (Koordination und Technik) sowie das handlungs- und verhaltensregulierende (Taktik und Psyche) System (Schnabel et al., 2005, S. 49).

Aus der Inanspruchnahme der Funktionssysteme ergeben sich akute Beanspruchungsfolgen. Schnabel et al. (2005, S. 57 - 61) sprechen hierbei allgemein von Ermüdungs- und Erholungsvorgängen. Hohmann et al. (2007) unterscheiden zwischen Ermüdungs- und Erholungsvorgängen der energieübertragenden und energiebereitstellenden Systeme sowie Verstärkungs- und Differenzierungsprozesse bei koordinativen, technischen, taktischen und psychischen Beanspruchungen. Ganz allgemein sind alle Reaktionen des Organismus auf einzelne reizwirksame Belastungen als akute Beanspruchungsfolgen zu betrachten. Aus einer physiologischen Perspektive werden akute, reversible Beanspruchungsfolgen unter dem Begriff Ermüdung zusammengefasst. Dazu gehören bspw. Veränderungen bei der Energiebereitstellung, die Auswirkungen von Stoffwechselendprodukten, eine reduzierte muskuläre Kontraktilität oder Beeinflussungen des Nervensystems. Folglich ist zwischen einer peripheren und zentralen Ermüdung zu differenzieren (Wilmore et al., 2008, S. 113). Aus dieser Abgrenzung geht auch der Vorschlag hervor, die Bezeichnungen von Schnabel et al. (2005) und Hohmann et al. (2007) im Belastungs-Beanspruchungsmodell zu ergänzen bzw. zu ersetzen (vgl. Abbildung 2.5).



**Abbildung 2.5:** Das prozessorientierte Belastungs-Beanspruchungs-Modell des Trainings (mod. nach Schnabel et al., 2005, S. 58).

Ein Vorteil des Belastungs-Beanspruchungs-Modells liegt darin, dass „eine konzeptionelle Verbindung zwischen den sportmotorischen Leistungsvoraussetzungen [...] und den von außen einwirkenden Belastungsanforderungen“ (Hohmann et al., 2007, S. 161) hergestellt wird. Zum anderen können im nächsten Schritt des prozessorientierten Konzepts Basismodelle der Leistungsveränderung integriert werden. Schnabel et al. (2005) sprechen bei den Mechanismen der Leistungsveränderung von bleibenden (chronischen) Beanspruchungsfolgen, die auf zwei Prinzipien beruhen: dem Modell der Superkompensation (Jakowlew, 1977) und dem Modell der Informationsorganisation (Stark, 1984; Hoffmann, 1993). Aufgrund weniger empirischer Belege wird die Praxisrelevanz dieser Modelle kritisiert (Hohmann, 2007; Hottenrott, 2010). Sie sind eher als Demonstrationsmodelle für die komplexen Anpassungsvorgänge zu betrachten. Es ist daher exakter von morphologisch-funktionellen Adaptation bei Veränderungen der konstitutionellen und konditionellen Leistungsvoraussetzungen sowie von Lernen bei Veränderungen koordinativ-technischer und taktischer Leistungsvoraussetzungen zu sprechen. Obwohl Lernvorgängen auch funktionelle und strukturelle Anpassungen zugrunde liegen (Kandel, Schwartz & Jessell, 2000), kann durch die begriffliche Differenzierung betont werden, dass z.B. zwischen einem Konditions- und einem Technik-/Taktiktraining auch methodische Unterschiede bestehen und unterschiedliche Funktionssysteme angesprochen werden.

Die chronischen Beanspruchungsfolgen nach wiederholt überschwelligen Belastungsreizen führen zu quantitativen und qualitativen Veränderungen aller Funktionssysteme. Dies ist gleichbedeutend mit der Entwicklung der Leistungsfähigkeit. Die Rückkopplung im Prozessmodell zeigt sich schließlich

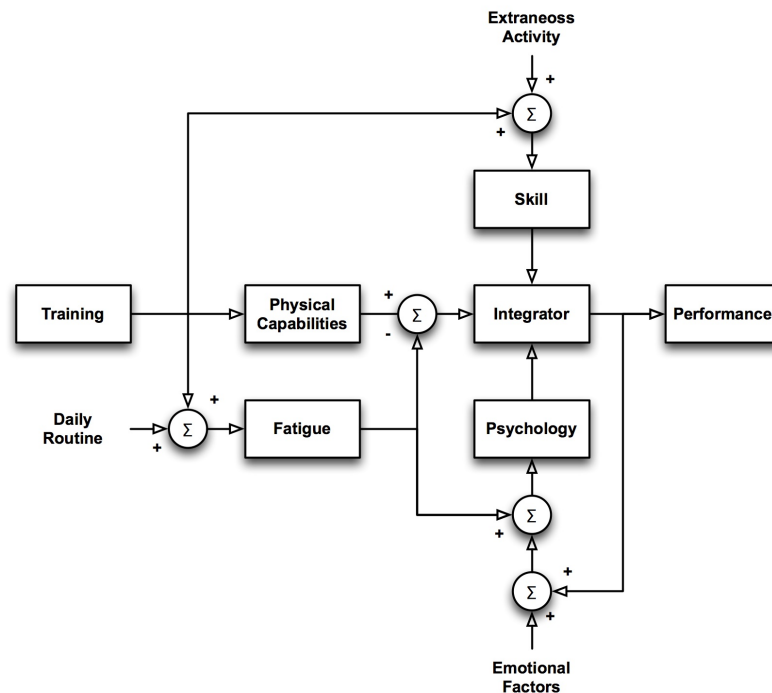
darin, dass der gleiche Belastungsreiz nach einer Leistungszunahme zu einer geringeren Beanspruchung führt.

Es ist zum einen kritisch anzumerken, dass beim Belastungs-Beanspruchungs-Modell ausschließlich Belastungen „in Form oder vermittelt der sportlichen Tätigkeit, des sportlichen Übens und Trainierens“ (Schnabel et al., 2005, S. 57) berücksichtigt werden. Kellmann und Kallus (2000) sehen darin eine verkürzte Betrachtungsweise. Als Belastungen gelten alle „objektive, von außen auf den Menschen einwirkende Größen und Faktoren“ (Rohmert & Rutenfranz, 1975). Daher sind neben den trainingsinduzierten Belastungen auch alle weiteren physischen, psychischen und sozialen Einflüsse der Lebenswelt eines Athleten zu berücksichtigen (Kellmann, 2002).

Andererseits ergibt sich der aktuelle Beanspruchungszustand nicht nur aus den einwirkenden Belastungen. Vielmehr hängt dieser auch von individuellen Bewältigungsmöglichkeiten ab (Schlicht, 1992) und ist durch das Verhältnis von Erholung und Belastung bestimmt. Erholung wird im Belastungs-Beanspruchungs-Modell als Kompensationsmechanismus einer beanspruchungsbedingten Auslenkung der Funktionssysteme betrachtet. Nach diesem Verständnis ist Erholung Teil des Mechanismus der Leistungsveränderung (Schnabel et al., S. 57 - 62). Erholung ist aber ein vielschichtiger aktiver Prozess, der Regenerationsmaßnahmen, Verhaltenskontrolle, soziale Aktivitäten usw. umfasst (Kallus & Kellmann, 2000; Kellmann & Kallus, 2000). Die Anforderungen an Erholungsmaßnahmen nehmen proportional zu den Belastungsanforderungen im Training zu und werden damit zu einem entscheidenden Erfolgs-/Misserfolgskriterium (Hohmann, 2005). Die Wirkung und das komplexe Zusammenspiel von Beanspruchung und Erholung muss in den Modellen des Trainings daher explizit einbezogen werden.

Die Schwierigkeit besteht aber darin, dass abgesehen von den physischen, trainingsbedingten Belastungen es kaum möglich ist, weitere soziale oder psychische Belastungen unmittelbar zu diagnostizieren. Die meisten Erholungsmaßnahmen entziehen sich ebenso einer direkten, quantitativen Messbarkeit. Damit besteht nur die Möglichkeit, über befindensorientierte Skalen indirekt Rückschlüsse auf Belastungen und Erholungsmaßnahmen zu ziehen. Standardisierter Methoden der psychologischen Erholungs-/Beanspruchungsdiagnostik ermöglichen es, den individuellen psychophysischen Zustand stabil, zuverlässig, sensitiv und ökonomisch zu erfassen (Kenttä & Hassmén, 1998). Zu den bekanntesten psychometrischen Verfahren gehört der Erholungs-Belastungs-Fragebogen (EBF-Sport; Kellmann & Kallus, 2000) und der profile of mood states (POMS) Fragebogen (McNair, Lorr, Droppleman, Biehl & Dangel, 1981).

Banister et al. (1975) beschreiben in einem wenig beachteten Modell in geeigneter Weise die mehrdimensionale Wirkungsrelation der Leistungsveränderung. Entscheiden dabei ist, dass neben den geplanten Trainingsinterventionen u.a. auch psychische Größen als leistungsrelevante Einflussfaktoren einbezogen werden (vgl. Abbildung 2.6). Damit erfüllt es im Wesentlichen die Forderungen, die sich aus der eben formulierten Kritik ergeben. Nicht berücksichtigt wird in diesem Modell hingegen der prozessorientierte, rückgekoppelte Zusammenhang zwischen der Inanspruchnahme von Funktionssystemen



**Abbildung 2.6:** Systemmodell der sportlichen Leistungsfähigkeit. Die Kernannahme des Modells geht davon aus, dass ein Trainingsreiz sowohl einen positiven Effekt durch eine Verbesserung der physischen Leistungsfähigkeit hat, als auch einen negativen Effekt durch eine Ermüdungskomponente auslöst. Beide Effekte werden integriert und ergeben den aktuellen Leistungszustand. Auf die Entwicklung der sportlichen Leistungsfähigkeit haben weitere trainingsbedingte, psychische und motorische Faktoren einen Einfluss (mod. nach Banister et al., 1975).


teme und der daraus resultierenden Systemveränderung. Obwohl das Modell in der Folge für die mathematische Beschreibung von Trainingswirkungen auf elementare Modellkomponenten reduziert wurde (vgl. Kapitel 2.4.1.1), eignet sich seine Grundstruktur als konzeptioneller Rahmen für weitere Modellentwicklungen.

## 2.2.2 Kybernetische Betrachtungsweise des Trainings

Die kybernetische Betrachtungsweise des Trainings bildet den gesamten Trainingsprozess ab (Zaciorskij, 1971; 1972). Der Bezug zur Kybernetik ergibt sich in diesem Modell dadurch, dass der Trainingsprozess als geschlossener Regelkreis betrachtet wird, der stabil gegenüber äußeren und inneren Einflüssen ist (Carl, 1983). Man geht davon aus, dass die Leistungsveränderung exakt über die Stellgröße Trainingsbelastung gesteuert werden kann. Der Ausgangspunkt des gesamten Trainingsprozesses ist dabei die Trainingsplanung, in der Sollwerte für die Entwicklung der Leistungsfähigkeit sowie für die Trainingsstruktur und -inhalte definiert werden. Die Planung erfolgt immer in Abhängigkeit von den Trainingszielen und den vorherrschenden Rahmenbedingungen. Bei der praktischen Trainings-



durchführung werden die Trainingsinterventionen aus dem Planmodell umgesetzt. Die Interventionen führen dann bei der Regelgröße Leistungsfähigkeit zu Ist-Wert-Veränderungen, die über die Instanz der Trainingskontrolle möglichst häufig und regelmäßig diagnostiziert werden. Abschließend werden bei der Trainingsauswertung die Sollwerte der Planung mit den Ist-Werten der Diagnostik verglichen. Sofern noch Soll-Ist-Differenzen vorliegen, kann über den beschriebenen Regelkreis eine weitere Steuerung der Leistungsfähigkeit erfolgen. Aus kybernetischer Sicht ist das Ziel dann erreicht, wenn keine Abweichungen mehr zwischen angestrebter Anpassungsleistung und realer Leistungsfähigkeit vorliegen.



**Abbildung 2.7:** Regelkreismodell der kybernetische Betrachtungsweise des Trainings (mod. nach Hohmann et al., 2007).

Das Regelkreismodell wird von Hohmann et al. (2007, S. 173) kritisch diskutiert. Die Kritik richtet sich hauptsächlich gegen die Analogiebildung zur ingenieurwissenschaftlichen Regelungstechnik. Man müsste entsprechend dem technischen Vorbild von einer vollständig linearen, deterministischen Beschreibbarkeit und zugleich präzisen Steuerbarkeit des Trainings ausgehen. Die Komplexität des Trainings sowie vielfältige Wechselwirkungen mit der Umwelt sprechen gegen einen vollständig linearen und steuerbaren Prozess, wofür bisher auch empirische Evidenzen fehlen. Vielmehr ist von nichtlinearen Reiz-Wirkungs-Relationen auszugehen (Martin, Carl & Lehnertz, 1991).

### 2.2.3 Synergetische Betrachtungsweise des Trainings

Die Steuerung des Trainings kann mit den Modellen der Leistungsveränderung und der kybernetischen Betrachtungsweise nicht hinreichend beschrieben und erklärt werden. Das Belastungs-Beanspruchungs-Modell und die Mechanismen der Leistungsveränderung erklären ausschließlich Anpassungen auf der Ebene einzelner Funktionssysteme. Die komplexe Leistungsfähigkeit können diese Modelle nicht abbilden. Der Erklärungswert linearer Modelle für die Abbildung des gesamten Trainingsprozesses ist ebenfalls begrenzt.

Diese Diskussion verdeutlicht, dass man der Komplexität des Trainings bei der Entwicklung von adäquaten Modellen nur gerecht wird, wenn man aus einer ganzheitlichen Perspektive funktionelle Anpassungsmechanismen und Steuerungs- bzw. Interventionsstrategien integriert (Lames, 1996; Mester & Perl, 2000; Bügner, 2005; Edelmann-Nusser, 2005; Hohmann et al., 2007). Dieser Forderung entsprechen Hohmann et al. (2007), indem sie das Konzept einer synergetischen Betrachtungsweise des Trainings entwickelt haben. Die Synergetik ist eine umfassende Theorie der Selbstorganisation und verfügt über einen hohen Erklärungswert, um Phänomene des Trainings zu beschreiben und zu erklären (Haken, 1996).

Zum weiteren Verständnis werden im Folgenden grundlegende Begriffe und die zentralen Merkmale der Synergetik erläutert. Ein System ist eine Menge von Elementen oder Komponenten, die wechselseitig in Beziehung stehen. Die Komplexität ergibt sich aus der Vielzahl der Elemente oder Komponenten des Systems. Systeme, deren Zustand sich über die Zeit verändert, werden als dynamische Systeme bezeichnet. Ist die zeitliche Dynamik nicht durch eine eindeutige Ursache-Wirkungs-Relationen bestimmt, spricht man von einem nichtlinearen dynamischen System (Mainzer, 2008).

Die Strukturen komplexere Systeme lassen sich nicht auf einzelne Elemente zurückführen. Die mikroskopischen Zustände der Elemente und deren Wechselwirkungen bestimmen den makroskopischen Zustand des Systems. Daraus entsteht Chaos und Unordnung. In sogenannten offenen Systemen, die in einem Austauschprozess mit der Umwelt stehen, bilden sich aber auch neue Strukturen und Ordnungen durch Selbstorganisation aus. Haken (1995) begründete mit der Synergetik, der „Lehre vom Zusammenwirken“ eine Disziplin der Strukturwissenschaften, die der Frage nachgeht, wie diese Strukturen und Ordnungen in komplexen Systemen entstehen und aufrecht erhalten werden.

Haken hat für die Aufarbeitung der Selbstorganisation eine eingehende mathematische Theorie entwickelt. Es ist aber nicht nötig, für das Verständnis dieser Arbeit näher darauf einzugehen. Haken (1996, S. 23 - 24) weist darauf hin, dass die Synergetik kein Universalrezept ist, mit dem alle auftretenden Fragen bei komplexen dynamischen Systemen beantwortet werden können. Vielmehr schafft sie einen allgemeinen theoretischen Rahmen, der von den jeweiligen Wissenschaftsdisziplinen mit eigenen Fragestellungen und Inhalten gefüllt werden muss. Von Relevanz sind daher lediglich die grundlegenden Begriffe und Prinzipien, damit die synergetische Betrachtungsweise als Modell des Trainings vorgestellt und begründet werden kann. Die Theorie der Synergetik kommt dabei mit relativ wenigen Begriffsbildungen aus: Stabilität und Instabilität, Kontrollparameter, Ordnungsparameter, Versklavung, Symmetriebruch, Fluktuationen sowie kritisches Langsamerwerden (ebd.).

Komplexe Systeme bilden häufig stabile, makroskopische Ordnungsstrukturen aus. Systemstrukturen sind aber keine einfachen, additiven Verbindungen der Systemelemente. Die Voraussetzung für deren Entstehung ist eine Vielzahl nichtlinearer Systemelemente. Damit sich Selbstorganisationseffekte einstellen, muss das System in einem ständigen Energie- und Informationsaustausch mit der Umwelt stehen. Andernfalls strebt es dem irreversiblen Zustand des thermodynamischen Gleichgewichts (Unordnung) zu. Aus der Koordination der Elemente ergeben sich kollektive Variablen oder Ordnungs-

parameter, die das Entstehen von Mustern neuer Ordnungen und Strukturen in komplexen Systemen charakterisieren (Birklbauer, 2005).


Alle natürlichen Systeme weisen zudem ständig zufällige Schwankungen bzw. ein Rauschen auf. Diese Fluktuationen beeinflussen den stabilen Systemzustand, um neue bzw. unterschiedliche Lösungswege einer Systemkonfiguration einzunehmen. Phasenübergänge zu neuen Ordnungsstrukturen entstehen dadurch, dass von außen variierbare unspezifische Kontrollgrößen oder Kontrollparameter verändert werden und damit das Systemgleichgewicht zunehmend instabiler wird. Störungen der Stabilität werden durch den Einfluss der Kontrollparameter verstärkt und lassen sich daher immer langsamer korrigieren (kritisches Langsamerwerden). Wenige Systemelemente bestimmen schließlich die Emergenz eines chaotischen Systems. Durch verstärkte Fluktuationen nehmen kollektive Wechselwirkungen zwischen den mikroskopischen Komponenten zu und dienen als neue Ordnungsparameter bzw. Ordner. Die Ordner verpflichten andere Systemteile nach dem Versklavungsprinzip. Dadurch gelingt es einem oder wenigen Ordnern, das Verhalten aller Systemelemente zu regulieren und zu kontrollieren. Das Auftreten des Ordners auf der einen Seite und das kohärente Verhalten der Systemelemente auf der anderen Seite bedingen sich gegenseitig. Es entsteht eine zirkuläre Kausalität, die ein weiteres kennzeichnendes Merkmal der Synergetik ist (Haken, 1995; Birklbauer, 2005; Mainzer, 2008).

Prinzipiell können an Instabilitätspunkten verschiedene, zueinander symmetrische Strukturen entstehen. In welche Richtung sich das System dabei entwickelt, hängt von kleinen, zufälligen Abweichungen der Anfangsbedingungen ab. Das System muss aber eine Auswahl unter gleichermaßen möglichen Ordnungsstrukturen treffen. Dabei kommt es zum Bruch der Symmetrie. Diese Zufallsfluktuationen können bei einer geometrischen Veranschaulichung als Verzweigungspunkte möglicher Entwicklungslinien dargestellt werden (vgl. Abbildung 2.8).

Von hoher Relevanz für das Konzept der Synergetik ist die Suche nach geeigneten Kontroll- und Ordnungsparametern (Birklbauer, 2005, S. 253). Nur so ist es zum einen möglich, die Instabilität eines Systems zu vergrößern und dessen Emergenz zu initiieren. Zum anderen sind makroskopische Größen nötig, mit denen der Systemzustand beschrieben und kontrolliert werden kann. In der Regel ist es einfacher, geeignete Kontrollparameter zu finden, wohingegen ein Ordnungsparameter bzw. eine kollektive Variable wesentliche Kriterien erfüllen muss: einerseits muss er den Ordnungszustand eines Systems hinreichend charakterisieren und zudem den Anspruch der zirkulären Kausalität erfüllen. D.h. der Ordnungsparameter muss sich aus der Koordination der Systemelemente ergeben und gleichzeitig deren Verhalten bestimmen.

Mit der synergetischen Betrachtungsweise wird der theoretische Rahmen der Synergetik aufgegriffen und ein ganzheitliches Modell des Trainings formuliert. An die ersten konzeptionellen Überlegungen von Hohmann et al. (2007) knüpft Ganter (2009, S. 31 -34) an und erarbeitet einen „systemtheoretischen Ansatz zur Beschreibung der Leistungsentwicklung im Trainingsprozess“.

Ausgangspunkt des Modellansatzes ist es, dass die sportliche Leistungsfähigkeit mit einem oder wenigen Ordnungsparametern dargestellt werden kann. Ganter (2009, S. 31) beschränkt sich in seinem systemtheoretischen Ansatz auf die Entwicklung der Komponenten der Leistungsfähigkeit im Trainings-



**Abbildung 2.8:** Bifurkationsdiagramm. Eine höhere oder niedrigere sportliche Leistungsfähigkeit kann sich zufällig als neuer stabiler Systemzustand an einem Instabilitätspunkt einstellen.

prozess. Eine Begrenzung auf die Leistungsvoraussetzungen ergibt insofern Sinn, da zwischen dem Training, der Leistungsfähigkeit, der Leistung im Wettkampf und dem sportlichem Erfolg kein linearer, kontingenter Zusammenhang, „sondern eine komplex determinierte, situationsabhängige, „chaotische“ und damit nicht zufrieden stellend prognostizierbare Beziehung“ (Hohmann et al., 2007, S. 199) besteht. Hierbei ist davon auszugehen, dass die Entwicklung der komplexen Wettkampfleistung umso weniger allein durch das Training aufgeklärt werden kann, je komplexer die Leistungsstruktur einer Sportart ist.

Der systemtheoretische Ansatz von Ganter (2009) sieht auf der makroskopischen Steuerungsebene eine Planungsinstanz vor, in der ausgehend von den Trainingszielen der Ablauf und die Inhalte festgelegt werden (vgl. Hohmann, 1994). Die Trainingsbelastungen führen auf mikroskopischer Ebene zu einer Inanspruchnahme des gesamten Systems oder einzelner Subsysteme und verstärken als Kontrollparameter die Instabilität des Systems. Daher sind Effekte einer erhöhten oder verringerten Trainingsbelastung nicht unmittelbar zu beobachten, sondern ergeben sich mit zeitlicher Verzögerung aus den Wechselwirkungen und der Selbstorganisation der Subsysteme. Die verstärkten Fluktuationen führen zu einem veränderten Leistungszustand als neue Entwicklungslinie an Bifurkationspunkten. Einerseits kann sich bei geeigneter Reizkonfiguration eine stabile, positive Leistungsentwicklung einstellen. Andererseits kann ein Bifurkationspunkt aber genauso der Punkt sein, an dem zu hohen Belastungen eine negative Entwicklung des Systems in Richtung eines Übertrainingszustands auslösen (Sands & McNeal, 2000).

In gleicher Weise wie im Belastungs-Beanspruchungs-Modell werden in der synergetischen Betrachtungsweise des Trainings und im systemtheoretischen Ansatz von Ganter (2009) als Kontrollgrößen bisher nur Trainingsbelastungen berücksichtigt. Auf der Basis der Kritik am Belastungs-Beanspruchungs-Modell und als Grundlage für diese Arbeit wird der Ansatz von Ganter (2009) zu einem eigenen system-

dynamischen Modell des Trainings erweitert. Ausgehend von der Annahme, dass die Inanspruchnahme der Funktionssysteme Veränderungen der Leistungsfähigkeit auslöst, ist nicht die Belastung sondern die Beanspruchung als Kontrollparameter zu betrachten. Der Beanspruchungszustand ergibt sich aus der Wechselwirkung von Erholungsmaßnahmen und von trainingsinduzierten, weiteren physischen, psychischen sowie sozialen Belastungen (Richardson, Andersen & Morris, 2008). Auf der Ebene der Trainingssteuerung wird der ganzheitliche Ansatz um die Instanzen „Belastung“ und „Erholung“ ergänzt (vgl. Abbildung 2.9). Der Bezug dieser Komponenten zur Trainingsplanung macht deutlich, dass ein wesentlicher Teil der Belastungen und Erholungsmaßnahmen im Rahmen der Trainingsplanung intendiert sind. Unspezifisch sind hingegen die Wirkungen exogener Umwelteinflüsse. Der Mechanismus der Leistungsveränderung wird analog zum systemtheoretischen Ansatz Ganter (2009) in das Modell integriert.




Abbildung 2.9: Systemdynamisches Modell des Trainings (mod. nach Ganter, 2009, S. 33).

Bisher befindet sich der synergetische Betrachtungsweise des Trainings noch in der theoretischen Konstruktionsphase. Dennoch liegen plausible Argumente für eine inhaltlich-logische Gültigkeit vor, die sich aus trainingspraktischen Erfahrungen ableiten lassen (Hohmann et al., 2007, S. 176):

- Ein gleicher Leistungszustand kann von verschiedenen Ausgangszuständen erreicht werden.
- Ein bestimmter Leistungszustand ergibt sich gleichermaßen bei unvollständiger oder leicht-variierender Belastungsdynamik.

- In der Belastungsgestaltung sind Toleranzbereiche vorhanden, die zu vergleichbaren Anpassungen führen.

Dies bedeutet für die Steuerung eines Trainingsprozesses, dass Belastungen und Erholungsmaßnahmen nur bis zu einem bestimmten Grad genau dosiert werden müssen. Sie müssen lediglich dafür geeignet sein, die Integrität des Systems so zu stören, dass entsprechende Anpassungen über Selbstorganisationsprozesse ausgelöst werden.

Aus der Sport- und Bewegungswissenschaft liegen bisher nur wenige empirische Arbeiten zur Synergetik vor. Der Tagungsbericht eines Symposiums zum Thema "Synergetik und Systeme in Training und Wettkampf" (Janssen et al., 1996) setzt sich aus interdisziplinärer Perspektive mit Konzepten der Synergetik auseinander und stellt Möglichkeiten dar, wie sie auf die Sportwissenschaft übertragen werden können. Hervorzuheben sind die systemdynamischen Modelle zur Kontrolle und Steuerung von Bewegungen (Haken, 1995; Birklbauer, 2006). Besonders das Haken-Kelso-Bunz-Modell zur Bewegungskoordination zeigt die Tragweite synergetischer Konzepte auf (Haken, Kelso & Bunz, 1985; Haken, 2004).

Aus aktuellen Arbeiten ergeben sich erste Hinweise, die das theoretische Konzept der synergetische Betrachtungsweise des Trainings unterstützen (Bügner, 2005; Schmidt, 2005; Ganter, 2009). Im Wesentlichen ist die Ergebnisinterpretation bisher aber auf deskriptive und qualitative Aussagen eingeschränkt. Vor allem durch die Entwicklung eines entsprechenden methodischen Inventars sind eindeutigere Belege oder sogar praktische Anwendungen zu erwarten (Hohmann et al., 2007; Ganter, 2009).


#### 2.2.4 Trainingsdiagnostik

Ziel der Trainingssteuerung ist es, in einem komplexen dynamischen Prozess mit gezielten Maßnahmen Sollwerte der Trainingsplanung zu erreichen. Sowohl die Zielplanung als auch die Zielerreichung sollte durch eine kontinuierliche Diagnostik unterstützt werden. Die Trainingsdiagnostik unterteilt man in eine Kontroll- und eine Auswertungsinstanz (vgl. Abbildungen 2.4 und 2.10).

„Bei der Trainingskontrolle werden in einem Schritt zwei Arten von Kontrollverfahren eingesetzt, die Trainingsprotokollierung, bei der das absolvierte Training in geeigneten Kategorien erfasst wird, und die Leistungskontrolle, bei der der aktuelle Leistungszustand des Athleten diagnostiziert wird. Die beiden Arten von Ist-Daten werden im zweiten Schritt der Trainings- und Leistungsverlaufsanalyse in Bezug auf ihre Struktur untersucht und mit den ursprünglich geplanten Sollwerten verglichen. Im abschließenden dritten Schritt der Trainingswirkungsanalyse werden die Ist-Trainings- und die Ist-Leistungsdaten auf ihren Zusammenhang hin untersucht“ (Hohmann et al., 2007, S. 188 - 189).

Für die Steuerung des Trainings im modernen Leistungssport aber auch für Trainingsmaßnahmen im Rahmen der Gesundheitsförderung sind Kontroll- und Auswerteverfahren ein wesentliches Qualitätskriterium. In der trainingswissenschaftlichen Evaluationsforschung und Beratung nimmt die Diagnostik ebenfalls eine zentrale Rolle ein. Aus dem Konzept der „kontrollierten Trainingspraxis“ (Hohmann, 1994) leiten sich Anforderungen für eine optimale Trainingsdiagnostik ab:

- Die Kontrollverfahren sind möglichst rückwirkungsfrei einzusetzen.
- Der Trainingsprozess ist längsschnittlich und einzelfallbezogen zu dokumentieren.
- Die Trainings- und Leistungsdaten sind mit den Methoden der empirisch-statistischen Einzelfallanalyse auszuwerten.
- Die Informationen der Diagnostik sind direkt in das trainingspraktische Handeln umzusetzen.
- Die Ergebnisse mehrerer analysierter Trainingsprozesse sind zu vergleichen, um verallgemeinerte Befunde und Aussagen treffen zu können.



**Abbildung 2.10:** Übersicht zur Trainingsdiagnostik mit den Arbeitsschritten der Trainingskontrolle und der Trainingsauswertung (mod. nach Hohmann, 1994).

### 2.2.4.1 Trainingskontrolle

Die Voraussetzung für die Trainingsauswertung sind Verfahren zur Dokumentation des Trainings und zur Leistungskontrolle. Die Protokollierung des Trainings erfolgt in der Regel in Kategorien, in denen Trainingsinterventionen wirksam werden (kategoriale Trainingsprotokollierung). Dabei ist zwischen einer belastungs- und einer beanspruchungsorientierten Diagnostik zu unterscheiden. Unter dem belastungsorientierten Aspekt werden bspw. in den Kraftsportarten die Anzahl der Übungswiederholungen und die Übungsgewichte dokumentiert. In Fortbewegungssportarten wird der Trainingsumfang auch

häufig über die zurückgelegte Strecke bestimmt. Im Bereich des Technik- und Taktiktrainings kann die Anzahl der Übungswiederholungen und deren Dauer aufgezeichnet werden.

Vor allem im Technik- und Taktiktraining aber auch bei allen anderen belastungsorientierten Verfahren ergibt sich das Problem, wie die Belastungsintensität zu bestimmen ist (Hohmann, 1994). Aus dem Belastungs-Beanspruchungs-Modell und aus der Diskussion zur synergetischen Betrachtungsweise des Trainings ist jedoch abzuleiten, dass über eine reine Protokollierung des Belastungsumfangs hinaus die Inanspruchnahme der Funktionssysteme zu erfassen ist. Ohne relativen Bezug zu einer individuellen Intensitätsgröße kann ansonsten keine Aussage getroffen werden, in welchem Ausmaß und in welcher Richtung Belastungsreize trainingswirksam werden.

Ein beanspruchungsorientiertes Konzept zur Quantifizierung des Trainings ist für Ausdauersportarten vorhanden (Banister et al., 1986). Der Trainingsinput wird damit als dimensionsloser Trainingsimpuls (TRIMP  $W(t)$ ) nach Gleichung 2.1 berechnet:

$$W(t) = X \cdot D \cdot k \quad (2.1)$$

Die Intensität der Trainingseinheit geht durch den Faktor  $X$  in die Berechnung ein und stellt den Quotienten zwischen der Differenz von Trainingsherzfrequenz ( $HF_{train}$ ) und Ruheherzfrequenz ( $HF_{basal}$ ) sowie der Differenz zwischen maximaler Herzfrequenz ( $HF_{max}$ ) und Ruheherzfrequenz dar:

$$X = \frac{HF_{train} - HF_{basal}}{HF_{max} - HF_{basal}} \quad (2.2)$$

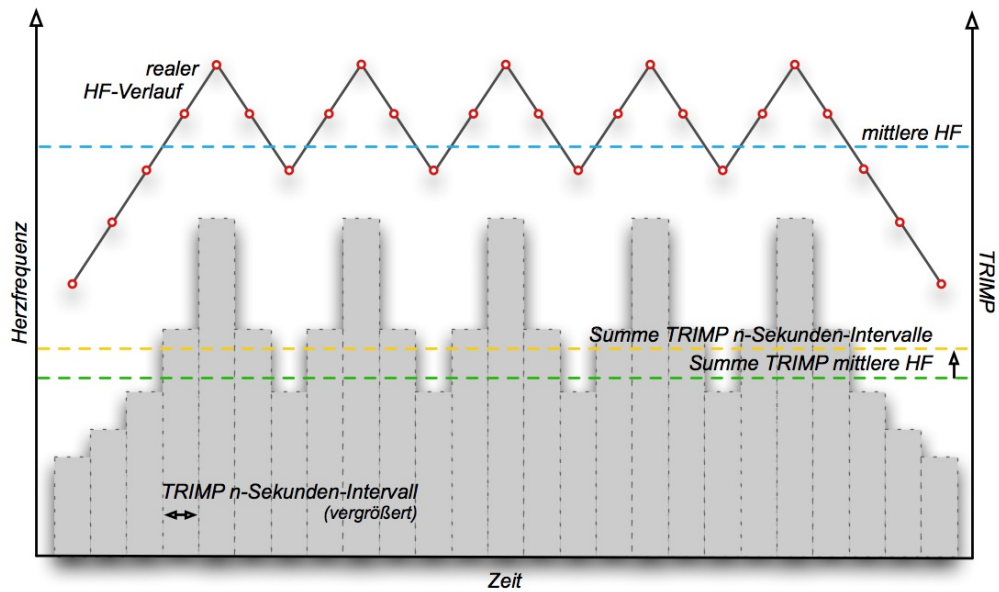
Der Faktor  $D$  ist der Umfang der Trainingseinheit in Minuten. Der nicht-lineare Gewichtungsfaktor  $k$  ist für weibliche Athleten  $0,86 \cdot e^{1,67X}$  und männliche Athleten  $0,64 \cdot e^{1,92X}$ . Er stellt sicher, dass sehr lange Trainingseinheiten mit niedriger Herzfrequenz nicht überproportional hoch gegenüber kurzen, intensiven Trainingseinheiten gewichtet werden. In den Gewichtungsfaktor  $k$  geht auch die geschlechtsspezifische Laktatkinetik bei zunehmender Belastung und Herzfrequenz ein, wie sie von Green et al. (1983) beschrieben wurde.

Morton, Fitz-Clarke & Banister (1990) weisen darauf hin, dass die Dynamik unterschiedlicher Trainingsformen bei der Berechnung des TRIMP zu berücksichtigen ist. Demnach ist die Summe der Trainingsimpulse möglichst kleiner Intervalle  $i$  einer Trainingseinheit und nicht der Trainingsimpuls anhand der mittleren Herzfrequenz zu bestimmen. Die Abbildung 2.11 veranschaulicht den Unterschied der beiden Verfahren. Der TRIMP  $W(t)$  einer einzelnen Trainingseinheit berechnet sich demnach wie folgt:

$$W(t) = \sum_{i=1}^j \frac{n}{60} \cdot X_i \cdot k_i \quad \text{mit } i = n\text{-Sekunden-Intervall} \quad (2.3)$$

Ein anderes Konzept zur Quantifizierung der Trainingsbelastung orientiert sich an der Laktatkonzentration im Blut. Dieses wurde vorrangig im Schwimmen eingesetzt (Mujika et al., 1994; Mujika et al., 1996; Avalos et al., 2003; Hellard et al., 2006). Die Intensitätsbestimmung erfolgt hier über definierte





**Abbildung 2.11:** Berechnung des Trainingsimpulses. Damit die Dynamik unterschiedlicher Trainingsformen berücksichtigt werden kann, ist der Trainingsimpuls (TRIMP) als Summe möglichst kleiner Intervalle zu bestimmen. Die Berechnung des TRIMP anhand der mittleren Herzfrequenz führt immer zu niedrigeren Werten (vgl. Morton et al., 1990). (HF = Herzfrequenz; TRIMP = Trainingsimpuls)

Trainingsbereiche, die sich aus einer Lakatadiagnostik ableiten. Weitere Konzepte der Intensitätsbestimmung beruhen auf der maximalen Leistungsfähigkeit, die auf einem Radergometer (Busso et al., 1991; Busso et al., 1997, Busso et al., 2002; Busso et al., 2003) oder als 1-Repetition-Maximum im Krafttraining (Busso et al., 1992; Busso et al., 1994) erreicht wird.

Die Leistungskontrolle erfüllt im Wesentlichen zwei Aufgaben. Zum einen können die Stärken und Schwächen für die Zielplanung im Trainingsprozess bestimmt werden. Zum anderen lassen sich aus einer kontinuierlichen Leistungskontrolle verlaufs- und interventionsbezogene Informationen für eine Trainingsauswertung ableiten.


Die Diagnostik der komplexen Wettkampfleistung erfolgt in der Regel mit sportartspezifischen Methoden der Wettkampfbeobachtung. Die Schwierigkeit hierbei besteht darin, im Wettkampf ein valides Kriterium rückwirkungsfrei messen zu können. Wesentlich einfacher können im Training mit psychologischen, biomechanischen, medizinischen oder motorischen Tests einzelne Komponenten der Leistungsfähigkeit diagnostiziert werden (Hohmann, 1994; Schnabel et al., 2005; Hohmann et al., 2007).

An die Testverfahren und die Testdurchführung sind bei der Leistungskontrolle besondere Anforderungen zu stellen. Die Testverfahren müssen das Leistungsmerkmal valide abbilden und gleichzeitig sensitiv für oftmals geringe Leistungsschwankungen sein. Bei einer Verlaufsdiagnostik ist besonders auf die Bedingungskonstanz während der Messung zu achten, um äußere und innere Einflüsse auf

das Messergebnis zu reduzieren. Darüber hinaus sind Lern-, Übungs- und Wiederholungseffekte zu berücksichtigen. Gewöhnt man die Versuchspersonen vor einem Untersuchungszeitraum an das Messverfahren, lassen sich diese Effekte ebenfalls vermeiden (Hohmann, 1994; Schnabel et al., 2005; Hohmann et al., 2007).

#### 2.2.4.2 Trainingsauswertung

Der erste Schritt der Auswertung von Trainings- und Leistungsdaten besteht darin, mit geeigneten Verfahren deren Verlauf zu beschreiben. Im nächsten Schritt geht es bei der Trainings- und Leistungsverlaufsanalyse darum, Ist- und Sollwerte zu vergleichen. Damit wird kontrolliert, ob die geplante Trainingsstruktur eingehalten wurde und die geplante Leistungsentwicklung eingetreten ist. Informationen über Abweichungen können genutzt werden, um damit die weitere Trainingsplanung zu korrigieren. Eine Übersicht über Verfahren der Trainings- und Leistungsverlaufsanalyse liefert die Abbildung 2.12.




**Abbildung 2.12:** Übersicht über Methoden der einzelfallbezogenen Trainings- und Leistungsverlaufsanalyse (mod. nach Hohmann et al., 2007).

Weitere Informationen über einen Trainingsprozess erhält man, wenn die Verlaufsdaten nicht nur isoliert betrachtet werden. Trainingseffekte sind vor allem auf die Interventionen und weniger auf andere Ursachen zurück zu führen. Mit einer Trainingswirkungsanalyse lassen sich Zusammenhänge zwischen einem Training und der Leistungsentwicklung aufklären (Calvert & Banister, 1976; Hohmann, 1994). In der Abbildung 2.13 werden in einer Übersicht verschiedene Methoden der einzelfallanalytischen Veränderungsmessung dargestellt. Zu unterscheiden ist dabei, ob diese Verfahren auf Ist-Istwert-Differenzen oder Ist-Istwert-Zusammenhänge beruhen. Dies hat einen entscheidenden Einfluss auf das Forschungsdesign. Für Ist-Istwert-Differenzanalysen werden lediglich Messreihen der Zustandsveränderung einer

Variablen benötigt. Deutlich aufwendiger sind Versuchspläne, bei denen die Abhängigkeit eines Kriteriums von Prädiktorvariablen untersucht wird. Bei Ist-Istwert-Zusammenhangsanalysen müssen neben der Kriteriumsvariable Interventionsgrößen parallel erfasst werden.

Mit den Methoden der Trainingswirkungsanalyse ist es möglich, „auf der Basis vorab ermittelter, individueller mathematisch-statistischer Funktionszusammenhänge eine simulative Folgenabschätzung für die geplanten Trainingsinterventionen“ (Hohmann, 2005, S. 58) vorzunehmen. Simulative Trainings-Wirkungs-Modelle bieten demnach die Möglichkeit, im individuellen Trainingsprozess bspw. für eine termingerechte Formsteuerung das Training zu optimieren. Der aktuelle Forschungsstand zu Methoden und Modellen der Trainingswirkungsanalyse wird in Kapitel 2.3.1 und 2.4 ausführlich diskutiert.



**Abbildung 2.13:** Übersicht über die Methoden der einzelfallbezogenen Trainingswirkungsanalyse (mod. nach Hohmann et al., 2007).

## 2.3 Zeitreihenanalyse und -prognose

Die Konzepte und Verfahren der Trainingsdiagnostik und -auswertung zeigen deutlich, dass wesentliche Informationen über einen Trainingsprozess nur mit individuumzentrierten Ansätzen zu erhalten sind. Besonders die Steuerung sportlicher Spitzenleistungen macht einzelfallanalytische Forschungsdesigns erforderlich. Entwicklungsverläufe in einem Trainingsprozess haben einen singulären Charakter, der sich aus einer Nicht-Wiederholbarkeit und dem Nicht-Vorhandensein von Vergleichs- oder Kontrollgruppen ergibt. Aus forschungsstrategischer Sicht kommt daher nur ein evaluatives Vorgehen für den Erkenntnisgewinn in Frage.

### 2.3.1 Zeitreihenanalyse

In der trainingswissenschaftlichen Grundlagen- und Anwendungsforschung dominieren weitgehend extensive Forschungsansätze (Schnabel et al., 2005; Hohmann et al., 2007). Daten werden in Gruppenuntersuchungen durch Aggregation gewonnen. Die Befunde aus der Verteilung von Merkmalen in

Stichproben werden dann auf die zugehörige Grundgesamtheit übertragen. Zubin (1950) formuliert Bedingungen, die für eine Stichprobenbildung erfüllt sein müssen und weist gleichzeitig darauf hin, dass in vielen Fällen einige der Voraussetzungen nicht gegeben sind. Mit vier methodisch-statistischen Axiomen begründet er, warum stattdessen bei Interventionsstudien einzelfallanalytische Untersuchungen mit Meßwiederholungen in Betracht zu ziehen sind.

Weitere inhaltlich begründete Vorteile und Sachzwänge machen Einzelfallanalysen in der Trainingswissenschaft nötig (Schlicht, 1988). Die Leistungsentwicklung eines Athleten wird durch den Trainingsprozess gesteuert. Der Prozess ist durch eine Verlaufscharakteristik gekennzeichnet, die durch Variabilität, intendierte Veränderungen und Interaktion mit der Umwelt bestimmt ist (vgl. Kapitel 2.2.3). Ein einzelfallbezogener (intensiver) und prozessanalytischer Ansatz ist dabei gegenüber einem gruppenstatistischen Ansatz im Vorteil, um nicht nur die individuelle Entwicklung und Variabilität der Leistungsfähigkeit darzustellen. Es sind vor allem interindividuelle Unterschiede der Wirkungsrelationen zu berücksichtigen. Bei Stichprobenbildungen und Mittelwertsberechnungen werden diese relevanten Merkmale verdeckt.

Insofern besteht in der Literatur Konsens darüber, dass die Analyse der sportliche Leistungsfähigkeit nur prozess- und einzelfallbezogen erfolgen kann. Schlicht (1988; 1990) schlägt daher aus inhaltlich-sachlogischer Sicht eine Vorgehensweise vor, wie man unter den ungünstigen Forschungsbedingungen der Trainingspraxis über evaluatives Wissen auch zu handlungsrelevantem und theoretischem Wissen gelangt:

1. Beschreibung des individuellen Leistungsverlaufs zur Hypothesen- und Konzeptgenerierung zu Regelmäßigkeiten und Wirkungszusammenhängen;
2. Präzisierung der theoretischen Vorannahmen durch explorative Studien;
3. Überprüfung der Hypothesen oder Konzepte in konfirmatorischen Replikationsstudien;
4. Ableitung technologischer Regeln oder Methoden;
5. Kausal-analytische Überprüfung der bewährten Hypothesen oder Methoden in extensiven Forschungsansätzen.

Aus diesen Arbeitsschritten ergibt sich ein sehr umfangreiches Forschungsprogramm, das bisher in dieser Form noch nicht vollständig umgesetzt wurde. Begründete Handlungsempfehlungen können aber auch schon nach den ersten beiden Schritten abgeleitet werden.

Petermann (1996) fasst das Anliegen der Einzelfallanalyse in einem allgemein gehaltenen Definitionsversuch zusammen:

- Gegenstand einer Einzelfallanalyse ist die Betrachtung einer einzelnen Untersuchungseinheit (Einzelperson, homogene Gruppe, komplexe Sozialstruktur, Gesellschaft oder Kultur).

- Einzelfallanalysen sind dann sinnvoll, wenn sich die Fragestellung auf die ganze Untersuchungseinheit und nicht auf einzelne Untereinheiten bezieht.
- Mit einer deskriptiven Einzelfallanalyse kann die Untersuchungseinheit bezüglich ihrer natürlichen, nicht experimentell beeinflussten Variabilität oder Stabilität untersucht werden. Davon lässt sich eine explikative Einzelfalluntersuchung abgrenzen. Sie fragt nach Gesetzmäßigkeiten von Prozessen und nach Effekten von Interventionen, auf deren Grundlage sich individuen-spezifische Prognosen ableiten lassen.

Der entscheidende Vorteil von Einzelfallanalysen ist darin zu sehen, dass die geringe Fallzahl häufige Messwiederholungen ermöglicht. Aus der „Folge von Messungen einer (oder mehrerer) Variablen an aufeinanderfolgenden Zeitpunkten“ (Schmitz, 1989, S. 11) ergeben sich Zeitreihen. Die Schwierigkeit liegt bei der statistischen Auswertung der Daten darin, dass von Abhängigkeiten zwischen den Einzelmessungen auszugehen ist. Dies verletzt die wesentliche Voraussetzung für gruppenstatistische Verfahren. Die statistische Abhängigkeit ist somit bei der Entwicklung und Wahl der Analyse- und Prognoseverfahren zu berücksichtigen (Schmitz, 1989; Schlittgen & Streitberg, 2001).

Die statistische Verarbeitung von Zeitreihen erfolgt mit den Methoden der Zeitreihenanalyse (Schmitz, 1989; Schlittgen & Streitberg, 2001). Revenstorf & Keeser (1996, S. 167-212) haben für die klinisch-psychologische Forschung Anwendungsgebiete der Zeitreihenanalyse diskutiert. Lames (1996, S. 49-50) hat diese Konzeption aufgegriffen und auf die Trainingswissenschaft übertragen. Daraus ergeben sich drei Anwendungsfelder in der trainingswissenschaftlichen Forschung:

- die Beschreibung von Verläufen,
- die Prüfung der Wirksamkeit von Interventionen und
- die Erfassung von Wirkungszusammenhängen.

Die Tabelle 2.1 liefert einen allgemeinen Überblick über die wesentlichen Analyseebenen, mögliche Fragestellungen und passende statistische Auswertungsverfahren.

Bisher wurden nur in einem begrenztem Umfang die Verfahren der Zeitreihenanalyse in der Trainingswissenschaft eingesetzt. Ordnet man die Arbeiten den Anwendungsfeldern der Zeitreihenanalyse zu, sind Untersuchungen zum langfristigen Leistungsaufbau oder zur Analyse der Entwicklung von Leistungsvoraussetzungen sowie physiologischer und psychologischer Parameter im Trainingsprozess zu finden (Schlicht, 1988; Schlicht & Janssen, 1990; Maas, Liesen, Mester, & Neumaier, 1995; Lames, 1996; Mester & Perl, 2000; Perl & Mester, 2001; Osterburg, 2004; Schmidt, 2005). Aufgrund ihrer wissenschaftstheoretischen und forschungsmethodologischen Bedeutung ist dabei die Arbeit von Schlicht (1988) hervorzuheben. Er konnte einen Nachweis dafür liefern, dass Einzelfallanalysen vor allem im Spitzensport eine Ergänzung der bis dahin bestehenden Forschungsstrategien der Trainingswissenschaft darstellen.

**Tabelle 2.1:** Übersicht über Analyseebenen, mögliche Fragestellungen und Auswerteverfahren der Zeitreihenanalyse (mod. nach Schlicht, 1990).

Analyseebene	Fragestellungen	Auswertungsverfahren
univariat	Wie hoch ist die durchschnittliche Trainingsbelastung	Plot und visuelle Inspektion, Mittelwert, Rang, Varianz
	Wie verhalten sich die Merkmale?	linearer Trend
	Sind Tendenzen erkennbar?	
	Variieren die Werte der Zeitreihe zufällig?	Autokorrelations-Analyse
	Existieren Wellen oder Zyklen?	Autokorrelations- und Spektralanalyse
bivariat	Kovariieren die Merkmale?	Kreuzkorrelationsanalyse
	Existiert eine zeitliche Reihenfolge, indem ein Merkmal einem anderen zeitlich nachfolgt (Lead-leg-Struktur)?	zeitverschobene Kreuzkorrelationsanalyse
	Zeigen zwei Merkmale einen zeit-synchronen Verlauf oder gibt es Phasenverschiebungen	bivariate Spektralanalyse

Im Kontext trainingswissenschaftlicher Forschung sind keine Studien zu finden, in denen die Wirksamkeit von Interventionen mit statistischen Zeitreihenanalysen geprüft wird. Lediglich Lames (1996, S. 49 - 50) konstruiert ein Beispiel für die anschaulichere Diskussion seiner Abgrenzung der oben genannten Anwendungsfelder.

Von besonderer Relevanz für den Gegenstand dieser Arbeit sind die Untersuchungen, die sich mit der Erfassung von Wirkungszusammenhängen beschäftigen (Hohmann, 1986; Mester & Perl, 2000; Ferger, 1998; Osterburg, 2004). Hohmann hat sich bereits 1986 mit der zeitlich-verzögerten Wirkung von Trainingsmaßnahmen im Sportspiel auf die individuelle Spielleistung beschäftigt. Ziel der Arbeit war es zu zeigen, dass sich „die sportliche Form prozessual in zeitlich kurzfristigem Zusammenhang mit der Dynamik des Umfangs“ (Hohmann, 1986, S. 7) verändert. Während eines einjährigen Trainingsprozesses im Wasserball wurde die Trainingsbelastung in verschiedenen Kategorien und die komplexe Spielleistung erfasst. Als Auswertungsmodell kam eine multiple Regression zur Anwendung. Damit konnten die zeitlichen Strukturen von Phasen mit positivem oder negativem Einfluss der Trainingsbelastungen auf die Spielleistung identifiziert werden. Hohmann zeigte mit seiner prozessdiagnostischen Analyse, dass die singulären und modellspezifischen Aussagen als Planungshilfen für die Konzipierung von Periodisierungsmodellen genutzt werden können.

Eine vergleichbare Arbeit hat Ferger (1998) veröffentlicht. Mit einem ähnlichen methodischen Instrumentarium hat sie einen fünf-monatigen Trainingsprozess einer Frauen-Fußball-Bundesliga-Mannschaft untersucht. Im Hinblick auf individuelle Anpassungsreaktionen konnte sie darstellen, wie sich „die individuelle Leistungsentwicklung in den einzelnen Trainingsphasen sowie charakteristische Anpassungsreaktionen für einzelne Spielerinnen“ (Feger, 1998, S. 105) bei einem standardisierten Mannschaftstraining entwickeln.

Eine sehr umfangreiche Einzelfall-Zeitreihenanalyse hat Osterburg (2004) im Langdistanz-Triathlon durchgeführt. Über einen Zeitraum von 5 bzw. 6 Monaten wurden die Trainingsbelastungen, die Ausdauerleistungsfähigkeit sowie eine Reihe physiologischer und psychologischer Parameter bei zwei Athleten mit hoher Dichte diagnostiziert. Neben einer genauen verlaufsanalytischen Auswertung der Daten ging Osterburg mit bivariaten Analysen der Frage nach, welche zeitlich-verzögerten Anpassungsreaktionen auf veränderte Trainingsbelastungen zu beobachten sind.

### 2.3.2 Zeitreihenprognose

Das Ziel der Zeitreihenanalyse ist es, in den Beobachtungen der Vergangenheit Strukturen, Zusammenhänge oder Gesetzmäßigkeiten aufzudecken. Damit besteht die Möglichkeit, die Information solcher Datenmodelle zu nutzen, um zukünftige Ereignisse vorherzusagen. Allgemein ist eine Prognose also „eine Aussage über ein oder mehrere zukünftige Ereignisse, die

1. auf Beobachtungen
2. auf einer Theorie

beruht“ (Hansmann, 1983, S. 11). Die erste Voraussetzung stellt einerseits sicher, dass Prognosen auf der Analyse der Vergangenheit beruhen und nicht das Ergebnis von Spekulationen sind. Andererseits sind Prognosen immer nur auf der Basis theoretischer Annahmen möglich (vgl. Kapitel 2.1). Dabei ist es zunächst einmal unerheblich, welchen Bewährungsgrad eine Theorie hat (Hansmann, 1983). Vielmehr kann eine gültige Prognose sogar den Bewährungsgrad einer Theorie erhöhen.

Zudem ist eine Prognose des zukünftigen Verhaltens einer Zeitreihe nur dann sinnvoll, wenn von einer zeitlichen Stabilität der angenommenen Gesetzmäßigkeiten ausgegangen werden kann. Diese Bedingung wird in der Ökonomie auch als Zeitstabilitätshypothese bezeichnet (ebd., S. 11-12). Legt man bei der Analyse und Prognose von Trainingswirkungen das Belastungs-Beanspruchungs-Modell oder die synergetische Betrachtungsweise des Trainings zugrunde, wird diese Voraussetzung streng genommen nicht bzw. nur bei einem stabilen Systemzustand erfüllt. Jede Belastung führt schließlich auch zu einer Veränderung des Systems selbst und zu veränderten Wirkungsrelationen. Somit kann nur der pragmatische Standpunkt eingenommen werden, dass die Zeitstabilitätshypothese im wesentlichen erfüllt wird. Dies hat wiederum zur Folge, dass immer von einem gewissen Prognosefehler auszugehen ist. Dieser Fehler lässt sich aber durch die Kontrolle der Systemstabilität und eine Berücksichtigung der Systemdynamik reduzieren.

Grundsätzlich kann zwischen qualitativen und quantitativen Prognosemodellen unterschieden werden. Zu den qualitativen Prognosemodellen gehören bspw. subjektive Einschätzungen oder Trendannahmen durch eine lineare Extrapolation. Für quantitative Prognosen wird Datenmaterial mit Hilfe mathematischer Operationen aufgearbeitet. Quantitative Prognosetechniken werden weiterhin noch in univariate oder multivariate Prognosemodelle unterteilt. Bei univariaten Modellen wird die Entwicklung einer Zeitreihe auf der Basis einer unabhängigen exogenen Variable oder autoregressiv durch die Zeitreihe der Zielvariable selbst vorhergesagt. Multivariate Verfahren verknüpfen entweder diese Ansätze oder es werden weitere Prognosevariablen hinzugenommen (Hansmann, 1983; Schlittgen & Streitberg, 2001).

Hansmann (1983, S. 13) stellt ein sehr feingliedriges Ablaufschema einer Prognose vor. Aus (forschungs-) ökonomischen Gründen kann das Schema auch vereinfacht werden. Die letzten beiden Schritte zählen nicht mehr zur eigentlichen Prognoseaufgabe, sichern aber den Systemzusammenhang und dienen der Rückkopplung für die weitere Entwicklung des Prognosemodells (vgl. auch Abbildung 2.2 zur Modellbildung):

1. Darstellung des Prognosegegenstandes
2. Formulierung eines Erklärungsmodells des Prognosegegenstands (theoretische Hypothesenbildung)
3. Untersuchung der Zeitstabilitätshypothese
4. Prüfung der Messbarkeit der Variablen
5. Suche nach messbaren Daten
6. Test des Erklärungsmodells
7. Anwendung des Prognoseverfahrens
8. Kritische Beurteilung der Prognoseergebnisse
9. Einsatz der Ergebnisse in der Planung
10. Ex-post Kontrolle der Prognoseergebnisse zur Gewinnung neuer Hypothesen

Die kritische Beurteilung des Prognoseergebnisses erfolgt überwiegend statistisch über die Genauigkeit der Prognose. Der Prognosefehler  $e_t$  ergibt sich aus der Differenz von tatsächlichem Wert  $x_t$  und prognostiziertem Wert  $\hat{x}_t$ :

$$e_t = x_t - \hat{x}_t \quad \text{mit dem Prognosezeitraum } t = T + 1, \dots, T + l \quad (2.4)$$

Die Prognosegüte kann mit zahlreichen Fehlermaßen beurteilt werden, in deren Berechnung immer der Prognosefehler  $e_t$  berücksichtigt wird (vgl. Bortz & Weber, 2005). Die Interpretationsmöglichkeiten sind aber eingeschränkt, wenn die Beurteilung der Prognose ausschließlich auf der Basis des Prognosefehlers



erfolgt. Es ist bspw. möglich, dass der Prognosefehler sehr gering ist, die Abweichungen aber nicht die gleiche Richtung haben. Daher sollte die Güte der Prognose sowohl durch ein Fehlermaß als auch durch ein Zusammenhangsmaß bestimmt werden. Die gängigsten Verfahren zur Beurteilung der Prognosegüte sind (Thiesing, 1998; Zhang et al., 1998):

- Mittlerer quadratischer Fehler (MSE):

$$MSE = \frac{1}{l} \sum_{t=T+1}^{T+l} e_t^2 \quad (2.5)$$

- Wurzel des mittleren quadratischen Fehlers (RMSE):

$$RMSE = \sqrt{MSE} \quad (2.6)$$

- Determinationskoeffizient ( $r^2$ ):

$$r^2 = \frac{[\sum (x - \bar{x})(\hat{x} - \bar{\hat{x}})]^2}{\sum (x - \bar{x})^2 \sum (\hat{x} - \bar{\hat{x}})^2} \quad (2.7)$$


## 2.4 Modelle zur Analyse und Prognose von Trainingswirkungen

Der Forschungsstand zu den operativen Modellen der Trainingswirkungsanalyse wird in den folgenden Kapiteln 2.4.1 - 2.4.3 anhand einer umfangreichen Literaturanalyse dargestellt. Im Anschluss daran erfolgt am Ende dieses Abschnitts eine vergleichende Bewertung der unterschiedlichen Verfahren.

### 2.4.1 Antagonistische Trainings-Wirkungs-Modelle

Die mathematische Modellierung von Trainingswirkungen geht auf Banister et al. (1975) zurück. Grundlage ihrer Überlegungen ist ein hypothetisches Systemmodell, das physische, psychische und technologische Einflussfaktoren auf die sportliche Leistungsfähigkeit und deren Interaktionen abbildet (vgl. Abbildung 2.6). Um die Komplexität für die mathematische Modellierung zu reduzieren, wurde die Kernannahme des Modells später isoliert (Calvert et al., 1976). Daraus ergibt sich die antagonistische Struktur des Fitness-Fatigue-Modells (FF-Modell): Ein Trainingsreiz wirkt sich gleichzeitig positiv (verstärkend) und negativ (hemmend) auf die sportliche Leistungsfähigkeit aus.

Das Fitness-Fatigue-Modell oder 2-Faktoren-Modell wird im folgenden Abschnitt detailliert beschrieben. Ein weiteres Modell mit antagonistischer Struktur wurde von Mester & Perl (2000) entwickelt. Das Performance-Potential-Modell (PerPot-Modell) ist ein informatives Metamodell zur Untersuchung kurz- und mittelfristiger physiologischer Adaptationsprozesse (vgl. Kapitel 2.4.1.2). Die Beschreibung der Modelle wird jeweils durch eine ausführliche Literaturübersicht ergänzt.



**Abbildung 2.14:** Das antagonistische Fitness-Fatigue-Modell (mod. nach Banister et al., 1975)

### 2.4.1.1 Fitness-Fatigue-Modell

Die Struktur des Fitness-Fatigue-Modells integriert zwei Transferfunktionen: Die individuelle Leistungsfähigkeit eines Athleten ergibt sich aus der Differenz eines trainingsinduzierten Aufbaus von Fitness und eines trainingsinduzierten Aufbaus von Ermüdung (Fatigue). Die positiven Effekte der Fitness-Komponente sind belastungsabhängige Adaptationen des Organismus. Die negativ wirkende Fatigue-Komponente stellt temporäre Ermüdungsprozesse dar. Jede Trainingsbelastung führt zu einer Zunahme der beiden Komponentenniveaus. Zu Beginn überwiegt die negative Wirkung der Fatigue-Komponente, was eine Abnahme der Leistungsfähigkeit zur Folge hat. Beide Niveaus nehmen nach Belastungsende exponentiell ab, wobei die zeitliche Verzögerung der Fitness-Komponente größer ist. Aus der schnelleren Abnahme der Ermüdung resultiert schließlich eine positive Entwicklung der Leistungsfähigkeit.

Ganz allgemein lässt sich das Modell mit folgender Gleichung beschreiben:

$$\text{performance} = \left( \begin{matrix} \text{fitness from} \\ \text{training model} \end{matrix} \right) - K \left( \begin{matrix} \text{fatigue from} \\ \text{training model} \end{matrix} \right) \quad (2.8)$$

Die Konstante K passt das Verhältnis zwischen dem Ermüdungs- und dem Fitness-Effekt an. Die antagonistischen Transferfunktionen leiten Calvert et al. (1975) aus zwei linearen Differentialgleichungen erster Ordnung ab. Die Lösungen der Differentialgleichungen sind zwei Exponentialfunktionen, die in die Modellgleichung für die Leistungsfähigkeit  $p(t)$  eingehen:

$$p(t) = \left[ \left( e^{-\frac{t}{\tau_1}} - e^{-\frac{t}{\tau_2}} \right) - K e^{-\frac{t}{\tau_3}} \right] * w(t). \quad (2.9)$$

Demnach nimmt die Leistungsfähigkeit in Abhängigkeit von der Trainingsbelastung  $w(t)$  zu.  $\tau_1$  und  $\tau_2$  sind die Zeitkonstanten der Fitness-Komponenten. Die Zeitkonstante der Fatigue-Komponente ist  $\tau_3$ . Calvert et al. (1976) berücksichtigen in ihrer Modellgleichung zwei Fitnesskomponenten. Lediglich eine Fitness-Komponente würde dazu führen, dass diese unmittelbar nach einem Trainingsreiz mit einer maximalen Zunahme reagiert. „This is considered to be nonphysiological since the systems involved require many hours to adapt in response to training“ (Calvert et al., 1976, S. 98).

In der Folge wurden einige Veränderungen der Modellgleichung vorgenommen. Banister & Calvert

(1980) haben eine Vereinfachung vorgenommen, indem sie nur noch eine Fitness-Komponente berücksichtigen. Eine inhaltliche Begründung der Vereinfachung wird nicht genannt. Dieser Ansatz wurde in der Arbeit von Morton et al. (1990) aufgegriffen. Sie unterscheiden ein kumuliertes Fitness-  $g(t)$  und Fatigueniveau  $h(t)$  zum Zeitpunkt  $t$ , die jeweils von der Trainingsbelastung  $w(t)$  abhängig sind:

$$g(t) = g(t-i)e^{\frac{-i}{\tau_1}} + w(t) \quad (2.10)$$

und

$$g(t) = g(t-i)e^{\frac{-i}{\tau_2}} + w(t), \quad (2.11)$$

wobei  $i$  der zeitliche Abstand in Tagen zwischen aktueller und vorangegangener Trainingseinheit ist.  $\tau_1$  und  $\tau_2$  sind die zeitlichen Konstanten der beiden Modellkomponenten. Die Gleichungen 2.10 und 2.11 werden zu einer linearen Differenzgleichung zusammengefasst, die Gewichtungsfaktoren  $k_1$  und  $k_2$  für die Fitness- und Fatiguekomponente enthält:

$$p(t) = k_1g(t) - k_2h(t). \quad (2.12)$$

Beinahe zeitgleich zur Arbeit von Morton et al. (1990) haben Busso et al. (1991) eine allgemeinere Formulierung des FF-Modells präsentiert. Die Modellgleichungen wurden dann noch in einer späteren Arbeit so modifiziert, dass sie sich in einer übersichtlichen Form darstellen lassen (Busso et al., 1994):

$$p_t = p_0 + k_1 \sum_{i=1}^{t-1} w_i e^{-\frac{t-i}{\tau_1}} - k_2 \sum_{i=1}^{t-1} w_i e^{-\frac{t-i}{\tau_2}} \quad (2.13)$$

Die Leistungsfähigkeit  $p_t$  am Tag  $t$  setzt sich aus der Summe der initialen Leistungsfähigkeit  $p_0$  und der positiven Fitness-Komponente zusammen, abzüglich einer negativen Fatigue-Komponente. Dabei ist  $w_i$  eine um  $i$ -Tage zurückliegende Trainingsbelastung.  $k_1$  und  $k_2$  sind Konstanten der Modellkomponenten sowie  $\tau_1$  und  $\tau_2$  die Zeitkonstanten der Modellgleichung.

Mit ihren modifizierten Modellgleichungen war es Busso et al. (1991) möglich, die Adäquanz unterschiedlicher Komponentenanzahlen statistisch zu prüfen. Transferfunktionen höherer Ordnung, wie sie ursprünglich von Calvert et al. (1976) eingesetzt wurden, führen nicht zu wesentlichen Verbesserungen der Modellanpassung, weswegen Busso et al. (1991, S. 2048) in ihrer Zusammenfassung feststellen: „A systems model composed of two antagonistic first-order transfer functions is supposed to provide a proper representation of the training responses.“

Als Input gehen in das FF-Modell die Zeitreihen der Trainingsbelastung ein. Die Zeitreihe der abhängigen Variable beschreibt den Modelloutput. Zu beachten ist, dass sowohl der Trainingsinput als auch der Leistungsoutput nur durch eine Variable repräsentiert sein kann. Daraus ergibt sich für die Anwendung des FF-Modell die Anforderung, die Trainingsbelastungen zur Ansteuerung konditioneller, koordinativer und technischer Größen zu einer Einheit zusammen zu fassen. Zudem müssen sowohl

verschiedene Trainingsformen als auch unterschiedliche Belastungsnormative vergleichbar gemacht werden müssen.

Das FF-Modell muss für den einzelnen Athleten über die Variation der Modellparameter  $\tau_n$  und  $k_n$  kalibriert werden. In einem iterativen Prozess werden die Parameter so modifiziert, dass aus der Modellkalibrierung eine möglichst geringe Abweichung zwischen modellierter und realer Leistungsfähigkeit resultiert. Die Anpassung erfolgt über die Methode der kleinsten Quadrate (Bortz & Weber, 2005). Aus den frühen Arbeiten der Gruppe um Banister (Calvert & Banister, 1976; Banister & Calvert, 1980; Banister & Hamilton, 1985) leiten sich Startwerte für die Modellanpassungen ab. Die Zeitkonstanten werden mit  $\tau_1 = 45 \text{ Tage}$  für die Fitness-Komponente und  $\tau_2 = 15 \text{ Tage}$  für die Fatigue-Komponente angegeben (Morton et al., 1990; Banister, 1991). Busso et al. (1997) geben 30 - 60 Tage für den Faktor  $\tau_1$  und 1 - 20 Tage für den Faktor  $\tau_2$  als möglichen Wertebereich an, wobei sich diese Angaben auf Ergebnisse eigener Untersuchungen beziehen. Eine Durchsicht der publizierten Arbeiten ergibt, dass die optimale Modellanpassung mit den Zeitkonstanten im Wertebereich von 13 - 65 Tage für  $\tau_1$  und 0,048 - 38 Tage für  $\tau_2$  erzielt wird. Die Gewichtungsfaktoren  $k_1$  und  $k_2$  streuen ebenfalls über einen großen Wertebereich. Wobei Busso et al. (1997) betonen, dass dies von der Methode zur Quantifizierung der Trainingsbelastungen und der Leistungsfähigkeit abhängig ist. „Only the ratio  $k_2/k_1$  can be thus compared between studies“ (Busso et al., 1997, S. 1685).

Morton et al. (1990, S. 1173) erläutern die Relevanz der Gewichtungsfaktoren:

„Although  $k_1$  and  $k_2$  have no direct physiological interpretation, individuals with a larger  $k_2$  may be characterized as having fatigue-dominated performance, taking longer to recover from heavy training, whereas individuals with a high  $k_1$  may be described as having fitness-dominated performance, recovering quickly from heavy training during tapering period.“

Diese Interpretation lässt sich ebenfalls auf die Zeitkonstanten  $\tau_1$  und  $\tau_2$  übertragen. Eine positive Leistungsentwicklung ist dann zu erwarten, wenn die Zeitverzögerung der Fatigue-Komponente eher klein und die Zeitverzögerung der Fitness-Komponente eher groß ist (Morton et al., 1997, S. 338).

Aus der Relation der Zeitkonstanten und der Gewichtungsfaktoren lassen sich wichtige Implikationen für die Steuerung des Trainings ableiten (Fitz-Clarke et al., 1991). Der Faktor  $\mu_{krit}$  kann als kritischer Zeitpunkt vor einem Wettkampf angegeben werden, ab dem durch ein Training keine positiven Effekte mehr auf die Leistungsfähigkeit zu erwarten sind. Ein Training nach diesem Zeitpunkt führt zu einer verhältnismäßig stärkeren Zunahme des Fatigue-Niveaus gegenüber dem Fitness-Niveau. Der Faktor  $\mu_{krit}$  berechnet sich nach Gleichung 2.14:

$$\mu_{krit} = \frac{\tau_1 \tau_2}{\tau_1 - \tau_2} \ln \frac{k_2}{k_1} \quad (2.14)$$

Der Zeitpunkt  $\mu_{opt}$ , an dem der höchste Trainingseffekt zu erwarten ist, kann ebenfalls mit den

Zeitkonstanten und Gewichtungsfaktoren berechnet werden:

$$\mu_{opt} = \frac{\tau_1 \tau_2}{\tau_1 - \tau_2} \ln \left( \frac{k_2 \tau_1}{k_1 \tau_2} \right) \quad (2.15)$$

Busso et al. (1997) machen in ihrer Arbeit deutlich, dass die Modellierung mit konstanten Modellparametern vor allem bei variierenden Trainingsbelastungen und -formen ungeeignet ist. Mit zeitvarianten Parametern ist eine bessere Modellanpassung zu erwarten: „However, day-to-day variations in model parameters, which would lead to a better fit of the performances, might describe more precisely adaptations to training and long-term fatigue“ (Busso et al., 1997, S. 1686).

Die Verbesserung der Modellanpassung führt aber nicht gleichzeitig zu einer besseren Vorhersagekraft des Modells. Die Werte der Zeitkonstanten und Gewichtungsfaktoren für den Simulationszeitraum ergeben sich aus der Modellkalibrierung. Bei einer zeitvarianten Modellierung liegen veränderliche Parameter vor, die eine Anpassung einzelner Modellwerte an die realen Messwerte verbessern aber kein globales Optimum darstellen. Daraus resultiert die Schwierigkeit, die richtige Modellkonfiguration für die Simulation zu bestimmen.

Eine Validierung des FF-Modell und der Modellkomponenten erfolgte in einer Vielzahl von Untersuchungen am Beispiel unterschiedlicher Sportarten und Leistungsniveaus. Hierfür wurde auch die Abbildungs- und Prognoseleistung sowie die Anwendbarkeit des Modells überprüft.

Calvert et al. (1976) haben in einer ersten Arbeit die Abbildungsleistung ihres Modells am Beispiel von zwei Trainingsperioden eines Schwimmers über 20 bzw. 24 Wochen verglichen, die zwei Jahre auseinander lagen. Die Gründe für die Abweichungen in der Güte der Modellanpassung zwischen realem und modellierten Leistungsverläufen bei beiden Testzeiträumen wurden weniger in der Vereinfachung des Modells als in externen Störgrößen gesehen, die sich aus dem alltäglichen Leben des Probanden ergeben. Aus dem Vergleich der Modellparameter der Trainingsperioden leiten Calvert et al. Hinweise auf einen veränderten Leistungszustand und das Adaptationspotenzial des Probanden ab. Während sich die Fatigue-Komponente im Vergleich nicht verändert hat, wirkte sich im zweiten Untersuchungszeitraum durch das höhere Leistungsniveau des Athleten ein Trainingsreiz weniger stark auf die Fitness-Komponente aus.

In einer experimentellen Validierung des FF-Modells haben Morton, Fitz-Clarke und Banister (1990) im Selbstversuch die Leistungsfähigkeit beim Laufen über einen Trainings- und Testzeitraum von ca. 80 Tagen modelliert. Sie verbesserten die Modellanpassung, indem sie zur Optimierung die Methode der kleinsten Quadrate einsetzten. Eine sehr guter Zusammenhang zwischen realem und modelliertem Leistungsverlauf wurde bei einem der Probanden beobachtet ( $r^2 = 0,96$ ).

In einigen weiteren Arbeiten bspw. im Gewichtheben (Busso et al., 1990), im Hammerwerfen (Busso, Candau & Lacour, 1994) oder auch in der Rehabilitation von Patienten mit Koronarer Herzkrankheit (Bris et al., 2004; Bris et al., 2006) wurden mit dem FF-Modell Anpassungen im Bereich von  $r^2 = 0,53$  bis  $r^2 = 0,92$  erreicht. Ganter, Witte und Edelmann-Nusser (2006) beobachteten über einen achtwöchigen Zeitraum ein individualisiertes Radtraining von zehn Sportstudierenden (9 männlich, 1 weiblich). Die aktuelle Leistungsausprägung wurde während eines 30-Sekunden-Maximalbelastungstests

bestimmt. Bei beinahe allen Probanden konnte das FF-Modell den Leistungsverlauf weitgehend gut abbilden ( $r^2 = 0,41$  bis  $r^2 = 0,92$ ). Bei einem Athleten wurde jedoch ein unbefriedigende Modellanpassung erzielt. Die Autoren führen dies auf eine zu geringe Dynamik der Leistungsentwicklung über den Untersuchungszeitraum zurück.

In mehreren Untersuchungen wurde die Modellgüte des FF-Modells anhand der einzelnen Modellkomponenten überprüft. Als Kriterien zur Validierung des Modells dienten hämatologische, hormonelle, psychologische und Leistungsparameter. Busso et al. (1990) überprüften in ihrer Arbeit den Zusammenhang zwischen den Modellkomponenten und bestimmten Hormonkonzentrationen. Hierfür dokumentierten sie bei sechs Gewichthebern über ein Jahr die Trainingsbelastungen, die Leistungsfähigkeit und die hormonellen Reaktionen. Die Autoren beobachteten hohe positive Korrelationen zwischen der modellierten Fitness und dem Serum-Testosteronspiegel, die aber nur bei zwei Athleten signifikant waren. Gleichzeitig stellten sie aber auch eine positive Korrelation zwischen der Fatigue-Komponente und dem Testosteronspiegel fest. Ungeklärt bleibt, warum die gleiche physiologische Variable in gleicher Richtung mit den Modellkomponenten in Verbindung steht.

Candau, Busso und Lacour (1992) wollten in ihrer Studie zeigen, ob ein quantitativer Zusammenhang zwischen hämatologischen Parametern und dem Umfang von Trainingsbelastung besteht. Während der 33-wöchigen Dauer der Studie wurden bei drei Skilangläufern das Training dokumentiert und alle zwei Wochen Blutproben entnommen. Die positiven Effekte des Trainings wurden über die Fitness-Komponente des FF-Modells abgeschätzt. Es zeigte sich, dass zwischen der Modellkomponente und den biologischen Größen ein Zusammenhang besteht. Die Ergebnisse bestätigen einerseits die bekannte Relation zwischen Erythrozytenbildung und Leistungsentwicklung. Andererseits stützen sie auch das grundlegende Modellverständnis, dass sich positive Effekte des Trainings mit der Fitness-Komponente beschreiben lassen.

In einer Einzelfallanalyse haben Wood et al. (2005) verschiedene Leistungsparameter und psychologische Größen in Verbindung zu den Modellkomponenten des FF-Modells gebracht. Hierfür wurde während einer zwölfwöchigen Trainingsperiode bei einem Läufer das Training dokumentiert und wöchentlich ein spezifischer Leistungstest sowie eine Ergospirometrie durchgeführt. Mit einer verkürzten Fassung des Profile of Mood States (POMS) Fragebogen wurde die wahrgenommene Müdigkeit erfasst. Für die Fitness-Komponente konnte eine signifikante Korrelation mit der Laufgeschwindigkeit an der ventilatorischen Schwelle und der Laufökonomie aufgeklärt werden. Die Fatigue-Komponente korrelierte ebenfalls signifikant mit einem Subtest des POMS. Wood et al. (2005) weisen darauf hin, dass in dieser Arbeit die Trainingswirkungen mit dem FF-Modell sehr gut abgebildet werden können. Zudem kann ein Teil der Varianz der Leistungsparameter und der psychologischen Größen über die Modellkomponenten aufgeklärt werden.

Die Prognoseleistung des FF-Modells wurde von Taha und Thomas (2003) überprüft. Sie verwendeten hierfür Daten aus einer Trainingsstudie von Hickson et al. (1981), bei der neun Athleten über einen Zeitraum von vier Wochen sechs Mal pro Woche 40 Minuten trainierten. Nach der ersten Trainingsperiode über vier Wochen wurde die Trainingsbelastung erhöht. Solange die Trainingsbelastung über

die ersten vier Wochen konstant gehalten wurde, konnte das FF-Modell den realen Leistungsverlauf sehr gut abbilden. Eine Anwendung des Modells mit konstanten Modellparametern auf die zweite Trainingsperiode reduzierte deutlich die Güte der Vorhersagegenauigkeit.

In der o.g. Studie von Ganter et al. (2006) wurde ebenfalls die Prognoseleistung des FF-Modells überprüft. Die Prädiktion der Leistungsfähigkeit über einen Zeitraum von sechs Tagen ergab für alle zehn Probanden eine mittlere Abweichung von 2,39 %. Bei zwei vergleichbaren Trainingsstudien von Pfeiffer und Perl (2009) über sechs bzw. acht Wochen ergaben sich für einen Prognosezeitraum von zehn Tagen für alle Probanden eine mittlere Abweichung von 5,44 %.

Das FF-Modell wurde von Mujika et al. (1994; 1996) eingesetzt, um Veränderungen der Leistungsfähigkeit in unterschiedlichen Trainingsphasen bei Schwimmern zu untersuchen. Sie stellten dabei fest, dass die Verbesserung der Leistungsfähigkeit durch die Reduktion des Belastungsumfangs in einer Taperphase eher auf eine Abnahme negativer als auf eine Zunahme positiver Einflüsse zurück zu führen ist. Während die Fitness-Komponente über den Untersuchungszeitraum ein weitgehend konstantes Niveau mit geringen Schwankungen aufwies, zeigte der Verlauf der Fatigue-Komponente eine enge Beziehung zur Trainingsperiodik. In Phasen hoher Belastung kam es zu einer starken Zunahme negativer Einflüsse durch die Fatigue-Komponente, die bei einer Belastungsreduktion aber auch wieder zurück gingen. Die Belastungsreduktion führt während einer Taperphase zu einer schnelleren Abnahme des Fatigue-Niveaus gegenüber dem Fitness-Niveau. In der Summe ergibt sich daraus ein positiver Effekt, der mathematisch auf die unterschiedlichen Zeitkonstanten der Modellkomponenten zurück zu führen ist.

In einer weiteren Anwendung des FF-Modells haben Banister, Carter und Zarkadas (1999) die Effektivität unterschiedlich gestalteter Taperphasen überprüft. Hierfür wurde zuerst die Entwicklung der Leistungsfähigkeit während der vier verschiedenen Taperphasen simuliert. Diese Ergebnisse wurden anschließend in einer empirischen Studie mit elf Triathleten überprüft und bestätigt. Das wesentliche Ergebnis dieser Arbeit ist es, dass das FF-Modell zur theoretischen Planung und Optimierung von kurzfristigen Belastungsgestaltungen eingesetzt werden kann.

#### **2.4.1.2 Performance Potential Modell (PerPot-Modell)**

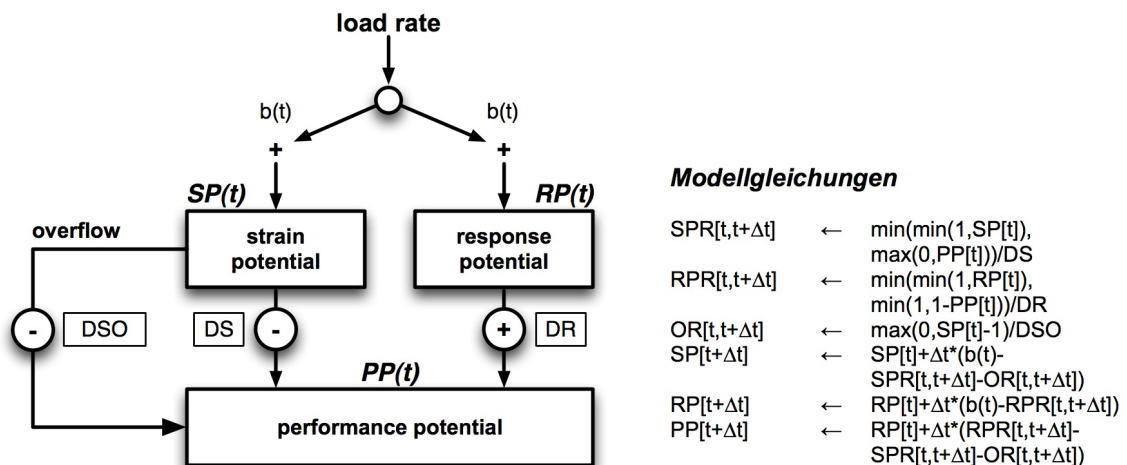
Neben dem FF-Modell ist das Performance Potential Modell (PerPot-Modell) ein weiteres Trainings-Wirkungs-Modell mit antagonistischer Struktur (Mester & Perl, 2000; Perl & Mester, 2001). Es handelt sich dabei um ein informatorisches Modell, das zur Untersuchung physiologischer Adaptationsprozesse entwickelt wurde. Mit dem systemdynamischen Ansatz werden drei Wechselwirkungsphänomene zwischen Belastung und Leistungsfähigkeit in einem sogenannten Metamodell abgebildet, d.h. und in einen strukturell übergreifenden Rahmen integriert:

1. ein Superkompensationseffekt bei konstanter Belastung,
2. ein Kollapseffekt bei einer spezifischen Überlastungssituation und

3. die umgekehrt U-förmige Leistungsentwicklung bei linear wachsender Belastung.

Neben der antagonistischen Modelldynamik ist das PerPot-Modell durch ein adaptives Systemverhalten charakterisiert, „d.h., das Modell beschreibt das durch externe Einflußgrößen provozierte Einschwingen eines Systems von einem Start in einen Zielzustand“ (Mester & Perl, 2000, S. 43).

Das zentrale Strukturelement des PerPot-Modells ist das Leistungspotential (performance potential,  $PP(t)$ ), das den aktuellen Zustand der Leistungsfähigkeit repräsentiert (vgl. Abbildung 2.15). Es ist in Abhängigkeit von der Trainingsbelastung (load rate,  $b(t)$ ) veränderbar. Alle Einflüsse auf das Leistungspotential sind zeitabhängig. Eine Trainingsbelastung  $b(t)$  wirkt sich als Modellinput auf ein Entwicklungspotential (response potential,  $RP(t)$ ) und ein Belastungspotential (strain potential,  $SP(t)$ ) in gleicher Weise aus und wird dort zwischengespeichert. Die antagonistische Struktur des PerPot-Modells ergibt sich dadurch, dass sich das Entwicklungspotential aufbauend (positiv) und das Belastungspotential abbauend (negativ) auf das Leistungspotential auswirken. Der Übergang bzw. Fluß von einem Potential in ein anderes Potential entspricht physiologischen Adaptationsprozessen, die in der Regel mit einer zeitlichen Verzögerung ablaufen. Diesen Prozessen wird im PerPot-Modell mit spezifischen Verzögerungsparametern entsprochen: Verzögerung des Entwicklungsflusses (delay in response flow,  $DR$ ) und Verzögerung des Belastungsflusses (delay in strain flow,  $DS$ ).



**Abbildung 2.15:** Das antagonistische Performance Potential Modell. Es werden auch die Modellgleichungen der Überlaufversion des PerPot-Modells dargestellt (mod. nach Mester & Perl, 2000).

Neben den absoluten Werten ist das Verhältnis der Verzögerungen ein wesentliches Merkmal der Modelldynamik. Wenn die Verzögerung des Entwicklungsflusses größer ist als der Fluss vom Belastungszum Leistungspotential, ergibt sich für den Leistungsverlauf die typische Charakteristik eines Superkompensationseffektes. Bei einem umgekehrten Verhältnis der Verzögerungsparameter ergibt sich ein Einschwingverhalten des Leistungspotentials (Mester & Perl, 2000).

Weitere Merkmale und Parameter legen die Eigenschaften des Metamodells fest: Für die Kapazitäten der natürlichen Potentiale werden im PerPot-Modell Ober- und Untergrenzen angenommen, die von



der Normierung der Daten abhängig sind. Der spezifische Startzustand für die Systemsimulation wird durch Startwerte der Potentiale festgelegt und charakterisiert. Minimum-Operatoren in den Flussgleichungen bedingen die Nicht-Linearität der Modells. D.h. maximale und minimale Werte begrenzen die Flüsse zwischen den Potentialen.

Die Basis-Struktur des PerPot-Modells ist noch nicht in der Lage, die Phänomene des Kollapseeffektes oder der umgekehrten U-Funktion abzubilden. Das Metamodell wurde hierfür um eine Überlauffunktion erweitert. Übersteigt das Belastungspotential bei zunehmender Trainingsbelastung seine Kapazitätsgrenze, fließt der Überlauf mit einer spezifischen Verzögerung (delay in strain overflow, *DSO*) und einer negativ Wirkung auf das Leistungspotential ab. Mester und Perl (2000) konnten durch diese „Überlauf-Version“ zeigen, dass neben dem akuten Kollapseeffekt bei Übertrainingssituationen auch das nicht-lineare Verhalten der Leistungsfähigkeit als umgekehrte U-Form bei linear steigender Belastung simuliert werden kann.

Mester und Perl (2000, S. 49) stellen zentrale Ergebnis ihres Ansatzes heraus:

- Das Metamodell erfüllt alle formulierten Anforderungen, die sich deduktiv aus den modellrelevanten Phänomenen ableiten.
- Der Charakter eines Metamodells zeigt sich darin, dass das Modell universelle Eigenschaften annimmt.
- Das Metamodell ist für Konkretisierungen und Verfeinerungen offen, um es an spezifische Problemsituationen anzupassen.

Die Struktur des PerPot-Modells wurde in einem Softwaresystem von der Arbeitsgruppe um Perl (Mester & Perl, 2000) umgesetzt. Eine Simulationsumgebung erlaubt es, „bei interaktiver Veränderung von Parameterwerten online die dadurch bewirkten Verhaltensänderungen zu simulieren und darzustellen“ (ebd., S. 49). Auch die individuelle Kalibrierung des Modells erfolgt softwareseitig. Ein genetischer Algorithmus bestimmt die Modellparameter so, dass die simulierten Leistungsdaten optimal an die originalen Leistungsdaten angepasst werden.

Im Rahmen der Trainingssteuerung bzw. Trainingswirkungsanalyse führen Mester & Perl (2000, S. 50 - 51) drei Einsatzszenarien an des PerPot-Modells an:

1. Informationen über einen Athleten gewinnt man mit dem PerPot-Modell durch die Anpassung der Modellparameter. Der Startwert charakterisiert den aktuellen Leistungszustand und die Überlaufparameter geben über die Belastbarkeit eines Athleten Auskunft. Aus dem Verhältnis der Verzögerungskonstanten  $DS$  und  $DR$  lassen sich Rückschlüsse auf die individuellen zeitlichen Reaktionen nach Trainingsbelastungen ziehen. Ergibt sich aus dem Quotienten der Konstanten ein Wert von  $\frac{DS}{DR} > 1$ , deutet dies auf eine spätere Reaktion der Entwicklungskomponente und einen gut-trainierten Zustand des Athleten hin (vgl. Ganter et al., 2006).

2. Mit dem PerPot-Modell kann der aktuelle Beanspruchungszustand eines Athleten bewertet werden. Die Reservefunktion der Überlauf-Version des PerPot-Modells gibt als Differenz zwischen der Maximalkapazität des Belastungspotentials und dessen aktuellem Bestand das Reserveprofil wieder. Die Kontrolle dieser Funktion ermöglicht es, auf den Beanspruchungszustand des Athleten zu schließen. So können bspw. kritische Zustände eines Athleten oder nachteilige Wirkungen des Trainings identifiziert werden.
3. Das PerPot-Modell kann auch zur Planung des Trainings eingesetzt werden. Es bietet prinzipiell die Möglichkeit, Prognosen der Leistungsentwicklung bei vorgegebenen Trainingsbelastungen zu erstellen. In der Simulationsumgebung lassen sich die Trainingsbelastungen simulativ verändern, damit bspw. die Trainingsbelastungen für eine maximale Leistungsentwicklung oder ein minimaler Belastungsumfang für ein vorgegebenes Leistungsprofil approximiert werden können.

Eine Validierung des PerPot-Modells haben Perl und Mester (2001) auf der Basis einer simulationsbasierten Kalibrierung vorgenommen. Die Idee beruht darauf, mit einer entsprechenden Suchstrategie diejenigen Modellparameter zu bestimmen, die am besten den modellierten Leistungsverlauf an die originalen Leistungsdaten approximieren. Die Güte der Anpassung ergibt sich aus der Abweichung zwischen den beiden Datenreihen. Perl und Mester (2001) weisen in ihrer Arbeit darauf hin, dass mit dem PerPot-Modell eine hohe Abbildungsleistung erzielt werden kann. Die verzögerte Dynamik des Modells kann aber auf spontane und extreme Veränderungen des Leistungsverlaufs nicht reagieren.

Bislang sind nur wenige Studien bekannt, in denen das PerPot-Modell eingesetzt wurde (Ganter et al., 2006; Torrents et al., 2007; Pfeiffer & Perl, 2009; Ganter, 2009). Im Radsport haben Ganter et al. (2006) die Modellgüte und die Prognoseleistung des FF-Modells und des PerPot-Modells miteinander verglichen. Hierfür wurde ein Radtraining von Sportstudierenden über acht Wochen dokumentiert. Der Trainingsinput wurde nach dem Konzept von Banister et al. (1986) bestimmt. Als abhängige Größe wurde die mechanische Leistungsfähigkeit während eines 30s Maximaltest (Wingate-Test) dreimal pro Woche erfasst. Die Prüfung der Modellgüte und der Prognoseleistung ergab für beide Modell stark variierende Ergebnisse, die keinen Vorteil eines Modells erkennen lassen. Der Determinationskoeffizient der Modellanpassung variiert zwischen  $0,00 < r^2 < 0,93$ . Der prozentuale Fehler der Prognose variiert zwischen 0,83 % und 8,29 %. Die Autoren stellen zusammenfassend fest, dass beide Modelle nicht in der Lage sind, kurzfristige Schwankungen im Leistungsverlauf hinreichend genau abzubilden.

Für den Vergleich zweier unterschiedlicher Krafttrainingsmethoden haben Torrents et al. (2007) die Trainingswirkungen mit dem PerPot-Modell bewertet. Bei zwei Aerobic-Athletinnen wurde eine Trainingsperiode von 18 Wochen analysiert, die Trainingsbelastungen quantitativ und qualitativ erfasst sowie täglich motorische Tests für die Leistungsdiagnostik durchgeführt. Als wesentliches Ergebnis in Bezug auf den Einsatz des Trainings-Wirkungs-Modells stellen Torrents et al. (2007) fest, dass bessere Ergebnisse erzielt werden, wenn der Modellinput quantitativ erfasst wird.

Ziel einer empirischen Arbeit von Pfeiffer & Perl (2009) war es, das FF-Modell mit dem PerPot-Modell u.a hinsichtlich

1. der Modellgüte,
2. der Prognosefähigkeit des Modells,
3. der Beziehung der Modellparameter untereinander (Kollinearität) und
4. der Abhängigkeit des Modellierungsergebnisses von der Auswahl eines belastungs- oder beanspruchungsorientierten Inputparameters

zu untersuchen und zu vergleichen.

An zwei Teilstudien über sechs bzw. acht Wochen nahmen jeweils 3 Probanden teil. Diese trainierten nach unterschiedlichen Trainingsprogrammen zwei- bis dreimal pro Woche auf einem Fahrradergometer. Während des Trainings wurde die mechanische Leistung als Belastungs- und die Herzfrequenz als Beanspruchungsparameter aufgezeichnet. Die Bestimmung der sportlichen Leistungsfähigkeit erfolgte vor jeder Trainingseinheit mit einem Maximal-Belastungstest.

Sowohl im Hinblick auf die Modellgüte als auch auf die Prognosefähigkeit sind keine wesentlichen Unterschiede zwischen den Modellen erkennbar. Eine Kollinearität der Modellparameter haben Pfeiffer & Perl (ebd.) für die Gewichtungsfaktoren des FF-Modells und die Verzögerungsparameter des PerPot-Modells festgestellt. Dies schränkt die Möglichkeiten einer unabhängigen kausalen Interpretation der einzelnen Parameter ein. In einer Teilstudie wurde ein Vergleich zwischen einem belastungs- und einem beanspruchungsorientierten Modellinput vorgenommen. Auch hier zeigt sich ein uneinheitliches Bild, sodass kein abschließendes Urteil zugunsten eines der Konzepte möglich ist.

Um „Hinweise für ein sich selbstorganisierendes systemdynamisches Verhalten“ (Ganter, 2009, S. 74) in einem Trainingsprozess zu bekommen, hat Ganter ebenfalls das FF-Modell und das PerPot-Modell vergleichend eingesetzt. Aus der Modellierung von trainingsbezogenen Daten im Schwimmen und Radfahren schließt Ganter (2009), dass dem nicht-linearen Ansatz (PerPot-Modell) gegenüber dem linearen Ansatz (FF-Modell) eine bessere Eignung zu bescheinigen ist.

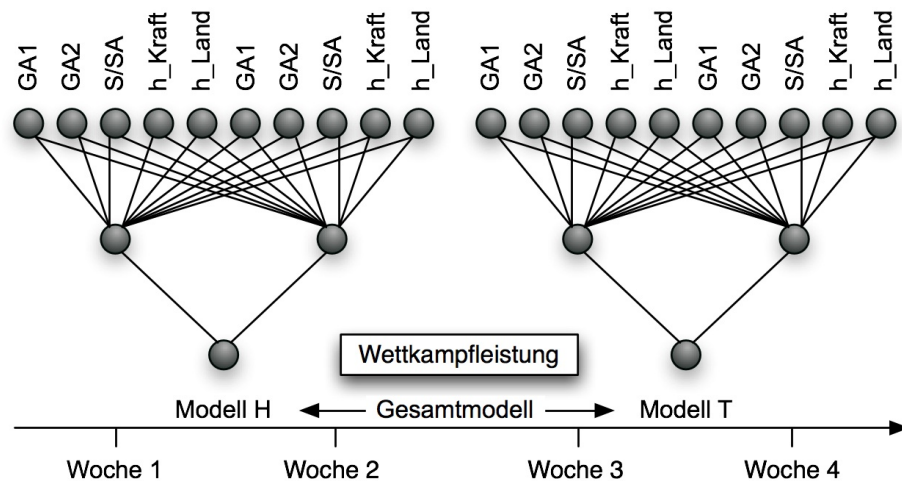
#### 2.4.2 Modellierung von Trainingswirkungen mit neuronalen Netzen

Die Arbeitsgruppe um Edelmann-Nusser (Hohmann, Edelmann-Nusser & Henneberg, 2000; Edelmann-Nusser, Hohmann & Henneberg, 2001; Edelmann-Nusser, Hohmann & Henneberg, 2002; Edelmann-Nusser, 2005; Bügner, 2005; Edelmann-Nusser, Hohmann & Henneberg, 2006; Ganter, Witte, Giggel & Edelmann-Nusser, 2008) konnte zeigen, dass es möglich ist, Wettkampfleistungen auf der Basis von Trainingsdaten der unmittelbaren Wettkampfvorbereitung mit künstlichen neuronalen Netzen vorherzusagen. Grundlage ihrer Überlegungen war es, dem komplexen und nichtlinearen Zusammenhang zwischen Training und Leistungsfähigkeit bei der Analyse methodisch zu entsprechen.

In diesem nicht-parametrischen Modellierungsansatz wurde das Konzept verfolgt, auf der Grundlage der Belastungen der letzten vier Wochen die Leistungsfähigkeit im Wettkampf oder Training zu bestimmen. D.h. den neuronalen Netzen wird die Zuordnung von Trainingsbelastungen über einen

bestimmten Zeitraum auf eine bestimmte Leistungsfähigkeit trainiert. Hierfür wurden drei Modelle entwickelt (Edelmann-Nusser et al., 2001, S. 20 - 21):

- **Modell T:** Ein neuronales Netz bildet den Zusammenhang zwischen den Trainingsbelastungen während einer zweiwöchigen Taperphase vor dem Wettkampf und der Wettkampfleistung ab.
- **Modell H:** Ein neuronales Netz bildet den Zusammenhang zwischen den Trainingsbelastungen während einer zweiwöchigen Hochbelastungsphase in den Wochen 3 und 4 vor dem Wettkampf und der Wettkampfleistung ab.
- **Gesamtmodell:** Die Ergebnisse von Modell H und Modell T werden durch Mittelwertbildung miteinander verrechnet. Damit wird ein vierwöchiger Zeitraum für die Modellierung der Leistungsfähigkeit berücksichtigt (vgl. Abbildung 2.16).



**Abbildung 2.16:** Trainings-Wirkungs-Modell auf der Basis neuronaler Netze. Die Wettampfleistung wird mit zwei Modellen anhand des kategorialen Trainingsinputs unterschiedlicher Trainingsphasen vorhergesagt (mod. nach Hohmann et al., 2000). (GA1 = Grundlagenausdauer 1; GA2 = Grundlagenausdauer 2; S/SA = Schnelligkeit/Schnelligkeitsausdauer; h-Kraft = Stunden Krafttraining im Wasser; h-Land = Stunden Krafttraining an Land)

Bis auf die Arbeit von Ganter et al. (2008), in der eine Trainingswirkungsanalyse im Bogenschießen durchgeführt wurde, kam das Modell ausschließlich im Schwimmen zum Einsatz. Die Modellierung erfolgte mit einem Multilayer-Perceptron (vgl. Kapitel 2.5.2), das aus 10 oder 14 Neuronen in der Inputschicht, einer verdeckten Schicht mit 2 Neuronen und einem Neuron in der Ausgabeschicht bestand. Sowohl im Schwimmen als auch im Bogenschießen setzten sich die Eingabemuster des Netzes aus Daten einer quantitativ kategorialen Trainingsprotokollierung zusammen. Im Schwimmen wurde Belastungsdaten in fünf Kategorien (vgl. Abbildung 2.16) und im Bogenschießen in sieben Kategorien erfasst. Den Eingabemustern wurden entsprechende Leistungen im Wettkampf oder Testleistungen im Training zugeordnet.

Die Ergebnisse von zwei Arbeiten (Edelmann-Nusser et al., 2001; Edelmann-Nusser et al., 2006) im Schwimmen bei den Olympischen Spielen 2000 und 2004 zeigen, dass die gewählte Methode zur Prognose der Wettkampfleistung geeignet ist. Die Abweichung der modellierten von der realen Wettkampfleistung einer Athletin betrug über die 200 m Rücken-Strecke nur 0,05 s bei den Olympischen Spielen 2000 und 0,41 s bei den Olympischen Spielen 2004. Die Autoren weisen aber daraufhin, dass die Ergebnisse nicht überinterpretiert werden dürfen, da sich aus der Validierung größere Erwartungswerte für Fehler der Modellierung ergeben.

Mit einer Simulation konnten Edelmann-Nusser et al. (2001) auch Probleme in der Vorbereitungsphase auf den Olympischen Wettkampf 2000 aufklären. Nachdem die Hochbelastungsphase aufgrund der Anreise nach Australien nicht wie gewohnt abgelaufen war, haben die deutschen Athletinnen und Athleten im Schwimmen entgegen den Erwartungen deutlich schlechtere Wettkampfleistungen erzielt. Die Simulation der Wettkampfleistung mit Daten aus einer bewährten Hochbelastungsphase ergaben den Erwartungen entsprechend höhere Leistungen.

In einer Arbeit von Bügner (2005) wurde mit dem gleichen Modellansatz die Wettkampfleistung einer Nachwuchsschwimmerin über einen Zeitraum von 250 Wochen modelliert. Die gute Prognoseleistungen aus den o.g. Arbeiten wurden nicht erreicht. Höhere Abweichungen zwischen den originalen und simulierten Leistungen ergaben sich auch bei der Modellierung im Bogenschießen (Ganter et al., 2008). Nach Meinung der Autoren ist im ersten Fall nicht von methodischen Ursachen für die größeren Fehler auszugehen. Es ist eher anzunehmen, dass die körperliche Entwicklung der Nachwuchsathletin über den langen Untersuchungszeitraum die Ergebnisse beeinflusst. Ganter et al. (2008) sehen im Bogenschießen die größte Schwierigkeit in der richtigen Diagnostik der Trainingsinhalte und der Leistungsfähigkeit.

### 2.4.3 Alternative Ansätze zur Modellierung von Trainingswirkungen

Im Vergleich zu den bereits vorgestellten Modellen zur Analyse von Trainingswirkungen wurden zu zwei weiteren Ansätzen deutlich weniger Arbeiten publiziert. Die Diskussion in diesem Abschnitt beschränkt sich daher auf eine kurze Darstellung und stellt die wesentlichen Unterschiede heraus.

Am Beispiel einer Trainingswirkungsanalyse im Volleyball haben Hohmann & Wichmann (2001) ein verlaufsorientiertes einzelfall-analytisches Verfahren aus den Sozialwissenschaften eingesetzt. Ziel dieser Studie war es, die Wirksamkeit verschiedener video- und computergestützter Interventionen bei einzelnen Rückrundenspielen mit Hilfe einer DEL-Analyse (Petermann, 1982) zu überprüfen. Die DEL-Analyse ist ein vergleichsweise voraussetzungsarmes und mit geringem Rechenaufwand verbundenes, nicht-parametrisches Verfahren. Es werden dabei die Fehler (d.h. bessere Resultate) von Ereignissen mit Interventionsstruktur und Ereignissen ohne Interventionsstruktur verglichen. Das Ergebnis einer DEL-Analyse ist die Aussage, ob die Interventionen zu einem überzufälligen Effekt geführt haben.

Hohmann & Wichmann konnten durch die Interventionen eine „Effektivitätssteigerung von 9,1% gegenüber einer „normalen“ Strategie bei der Wettkampfvorbereitung“ nachweisen (2001, S. 181). Durch eine simulative Veränderung der Input- und Outputdaten haben Hohmann & Wichmann die Sensitivität (Stabilität der Ergebnisse gegenüber Veränderungen der Modellparameter) überprüft. Die Aussagekraft der DEL-Analyse hängt zum einen davon ab, in welchem Verhältnis interventionsfreie zu interventionsgebundenen Messzeitpunkten stehen. Neben der Gesamtzahl beeinflusst zum anderen das Verhältnis zwischen erfolgreichen und erfolglosen Interventionen den Interventionseffekt.

Der wesentliche Vorteil einer DEL-Analyse liegt darin, dass bereits bei einer geringen Interventionshäufigkeit und -dichte eine Analyse gerechnet werden kann. Zudem genügt es, wenn die abhängige Variable nominalskaliert vorliegt. Aus mathematisch-statistischer Sicht ist eine DEL-Analyse ein querschnittliches Verfahren. Eine prozessdiagnostische Bewertung der Abfolge und Wirksamkeit von Einzelmaßnahmen ist somit nicht möglich. Zudem lässt sich eine DEL-Analyse nur durchführen, wenn eine interventionsfreie und eine interventionsgebundene Treatmentphase für den Vergleich und die Effektprüfung vorliegen.

Auf der Basis des PerPot-Modells haben Brückner und Wilhelm (2008) ebenfalls ein antagonistisches Trainings-Wirkungs-Modell entwickelt. Das SimBEA-Modell (Modell zur Simulation von Belastungs-, Ermüdungs- und Anpassungsprozessen) berechnet die Modellzustände auf der Basis vorhergehender Zustände. Veränderungen der Leistungsfähigkeit werden als Flüsse von einem Anpassungspotenzial modelliert. Die Modellstruktur berücksichtigt dabei sowohl negative als auch positive Anpassungen. Die individuelle Anpassung des Modells erfolgt wiederum über zeitliche Konstanten. Der wesentliche Unterschied zum Per-Pot- und FF-Modell liegt in der Grundannahme des SimBEA-Modells, dass „Training eine unmittelbare Abnahme der Leistungsfähigkeit bzw. eine Strukturzerstörung“ (Brückner & Wilhelm, 2008) zur Folge hat.

#### **2.4.4 Vergleich der Trainings-Wirkungs-Modelle**

Die Diskussion spezifischer Eigenschaften der vorgestellten Trainings-Wirkungs-Modelle erfolgt immer vor dem Hintergrund, inwiefern eine Entsprechung zum systemdynamischen Modell des Trainings vorhanden ist. In der Diskussion werden die alternativen Modellansätze (vgl. Kapitel 2.4.3) nicht berücksichtigt, da hierzu die empirische Datenlage zu gering ist.

Bei der Analyse- und Prognose von Trainingswirkungen muss die Abhängigkeit der Wirkung eines Trainingsreizes vom veränderlichen Systemzustand berücksichtigt werden. Mit einer bivariaten Zeitreihenanalyse sind nur Aussagen über zeitliche Strukturen des Zusammenhangs zwischen Belastungsumfängen und der Leistungsentwicklung möglich (Hohmann, 1988; Ferger, 1998). Mögliche veränderte Wirkungsrelationen aufgrund einer Leistungsentwicklung können mit statistischen Zeitreihenanalysen somit nicht berücksichtigt werden.

Die Modellstruktur des FF-Modells sieht ebenfalls keine Verknüpfung einer Wirkungsrelation von Trainingsreizen zur aktuellen Leistungsfähigkeit vor (Busso et al., 1994). Der Trainingseinfluss wirkt sich unabhängig von der Leistungsentwicklung auf die Modellkomponenten aus. Busso et al. (1997) haben daher zeitvariante Modellparameter verwendet, um Anpassungen an das Training berücksichtigen zu können (Sands & McNeal, 2000, S. 291). Hierbei ergibt sich aber das bereits erwähnte Problem, dass zeitvariante Parameter nur für die Phase der Modellkalibrierung bestimmt werden können. Für einen Prognosezeitraum liegt die Leistungsfähigkeit nicht als Bezugsgröße für die Anpassung der Parameter vor, da sie selbst das Merkmal ist, das über die Simulation ermittelt wird.

Der Ansatz der Modellierung von Trainingswirkungen mit neuronalen Netzen weist keine zeitliche Abhängigkeit auf. Vielmehr wird mit der unmittelbaren Wettkampfvorbereitung (UWV) nur eine kurze Phase im Trainingsprozess modelliert. Das Ziel dieses Ansatzes ist es auch, nicht die Leistungsentwicklung über einen längeren Zeitraum sondern nur einen Wert - die Wettkampfleistung nach der UWV - vorherzusagen. Damit wird explizit auf die Integration einer leistungsabhängigen Modellkomponente verzichtet. Dass die Analyse- und Prognoseleistung des Modellansatzes von der zeitlichen Stabilität der Leistungsfähigkeit abhängt, zeigt sich in der Arbeit von Edelman-Nusser, Hohmann, Bügner und Witte (2009) und stützt die bereits diskutierte Zeitstabilitätshypothese (vgl. Kapitel 2.3.2). Die Ergebnisse der Trainingswirkungsanalyse waren bei der Versuchsperson deutlich schlechter, bei der über den Untersuchungszeitraum eine Leistungsentwicklung von einem weniger stabilen, niedrigen Leistungsniveau zu einem stabileren und höheren Leistungsniveau zu beobachten war.

Das PerPot-Modell wurde im Besonderen dafür entwickelt, die zeitliche Dynamik des Trainingsprozesses abzubilden. Die Abhängigkeit der Belastungswirkung vom Leistungszustand ergibt sich aus der Systemeigenschaft, dass Kapazitätsgrenzen die Entwicklung des Leistungspotentials beschränken. Dies entspricht damit auch dem Quantitätsgesetz des Trainings, wonach das Ausmaß der Leistungsveränderung immer vom aktuellen Leistungsniveau abhängig ist (Letzelter, 1978; Martin et al., 1991; Mester & Perl, 2000, S. 48).

Die Berücksichtigung von Kapazitäten und Grenzen der Potentiale bedingt im PerPot-Modell die Nichtlinearität der Modellgleichungen. Damit basiert das PerPot-Modell auf den aktuellen Modellvorstellungen des Trainings, die von einem dynamischen und nichtlinearen Prozess ausgehen (vgl. Kapitel 2.2.3). Das FF-Modell und Zeitreihenanalysen basieren grundsätzlich auf linearen mathematischen Konzepten. Die nichtlineare und dynamische Modellierung von Trainingswirkungen ist ein entscheidender Entwicklungsschritt des PerPot-Modells (Edelman-Nusser et al., 2009; Pfeiffer & Perl, 2009). Die Ergebnisse der vergleichenden Arbeiten von Ganter et al. (2006), Pfeiffer und Perl (2009) sowie Ganter (2009) lassen bisher aber keinen eindeutigen Schluss zu, ob Unterschiede in der Eignung eines nichtlinearen gegenüber eines linearen Ansatzes bestehen.

Grundsätzlich scheint der Ansatz von Hohmann et al. (2000) besonders geeignet zu sein, den Zusammenhang von Trainingsinput und Leistungsfähigkeit abzubilden. Mit dem Einsatz neuronaler Netze wird eine methodische Entsprechung gegenüber der Komplexität und Dynamik des Trainingsprozesses verfolgt (Rojas, 1996; Zell, 2000; Zhang, Patuwo & Hu, 1998). Der Vorteil neuronaler Netze ist

darin zu sehen, dass sie gleichzeitig lineare und nichtlineare Beziehungen zwischen Trainingsreiz und Leistungsfähigkeit abbilden können (Hohmann et al., 2000, S. 37). Ein Vergleich der Analyse- und Prognoseleistung zwischen den antagonistischen sowie statistischen Modellen und dem Modellansatz auf der Basis neuronaler Netze zeigt ebenfalls ein uneinheitliches Bild. Zwar ist die Modellierung von Trainingswirkungen im Schwimmen mit neuronalen Netzen einer multiplen linearen Regression überlegen, bei einer vergleichenden Untersuchung im Bogenschießen werden aber mit dem PerPot-Modell bessere Ergebnisse erzielt. Dies wird von den Autoren aber auf methodische Probleme bei der Quantifizierung des Trainings zurück geführt (Hohmann et al., 2000; Ganter et al., 2009).

Wie bereits angeführt wurde, eignen sich bivariate Zeitreihenanalyse besonders dafür, die zeitlichen Strukturen der Belastungswirkungen aufzuklären. Damit erhält man wichtige Informationen für eine optimale Belastungsgestaltung. Bei den Arbeiten von Hohmann (1988) und Ferger (1998) waren vor allem die interindividuellen Unterschiede der zeitlichen Verzögerung von Anpassungen auf weitgehend einheitliche Belastungsreize von Interesse. Der Einsatz statistischer Zeitreihenanalysen kann in diesem speziellen Anwendungsfall brauchbare Aussagen liefern.

Verzögerungskonstanten bilden in den antagonistischen Modellen die zeitliche Struktur des Trainingsprozesses ab. Aus den Modellkonstanten des FF-Modells können kritische Zeitpunkte für die Belastungsgestaltung ermittelt werden (Fitz-Clarke et al., 1991). Die Zeitkonstanten für die optimalen Modellanpassungen streuen aber deutlich und liegen teilweise außerhalb eines Bereichs, der inhaltlich und physiologisch als sinnvoll zu interpretieren ist (Busso et al., 1997; Hellard et al., 2006; Ganter et al., 2006; Ganter, 2009; Pfeiffer & Perl, 2009). Kritisch ist außerdem anzumerken, dass der positive Fitness-Effekt des Trainings unmittelbar eintritt. Anpassungsprozesse finden jedoch mit einer zeitlichen Verzögerung statt. Damit eignet sich das FF-Modell allenfalls, um kurzfristige Schwankungen im Leistungsverlauf zu prognostizieren. Wegen der mangelnden physiologischen Entsprechung zweifeln Taha & Thomas (2003) aber an trainingspraktischen Einsatzmöglichkeiten des FF-Modells.

Für das PerPot-Modell kann analog über die Verzögerungswerte der positive und negative Trainingseinfluss zeitlich ausgedrückt werden. Auch hier sind große Schwankungen der zeitlichen Konstanten zu beobachten: Es ergeben sich Verzögerungswerte des Belastungspotentials ( $DS$ ) zwischen 10 und 55 Tagen und zwischen 8 und 44 Tagen für die Verzögerungswerte des Entwicklungspotentials ( $DR$ ) (Ganter et al., 2006; Torrents et al., 2007; Ganter, 2009; Pfeiffer & Perl, 2009). Ein Einsatzszenario des PerPots-Modells ist es, Informationen über einen Athleten zu gewinnen (vgl. Kapitel 2.4.1.2). Das Verhältnis der Verzögerungskonstanten soll darüber Auskunft liefern, ob sich der Athlet in einem gut- oder schlecht-trainierten Zustand befindet. Dieser Annahme entsprechen die Ergebnisse der Arbeiten von Ganter et al. (2006) und Ganter (2009). Torrents et al. (2007) beobachten hingegen bei Leistungssportlern im Krafttraining meist höhere Verzögerungswerte des Entwicklungspotentials. Einen entgegengesetzten Effekt beschreiben Pfeiffer & Perl (2009) bei einem Ausdauertraining mit untrainierten Sportlern. Da bisher nur wenige Vergleichsdaten und uneinheitliche Ergebnisse zu einer Modellierung mit dem PerPot-Modell vorliegen, ist eine physiologische Interpretation der Zeitkonstanten und deren Relation ebenfalls problematisch.



Hellard et al. (2006) kritisieren in ihrer Arbeit, dass zwischen den Modellkonstanten des FF-Modells lineare Abhängigkeiten bestehen. In einer weiteren Arbeit haben Pfeiffer & Perl (2009) die Modellparameter des FF-Modells und des PerPot-Modells bezüglich einer Kollinearität überprüft. Sie konnten hohe Zusammenhänge zwischen den Gewichtungsfaktoren des FF-Modells und den Verzögerungsparametern *DS* sowie *DR* des PerPot-Modells feststellen. Dies schränkt zusätzlich die kausale Interpretation der Modellparameter weiter ein.

Die zeitliche Dynamik des PerPot-Modells ist dadurch bestimmt, dass auflaufende Belastungen in Potentialen zwischengespeichert werden und sich mit einer entsprechenden zeitlichen Verzögerung positiv sowie negativ auf die Leistungsfähigkeit auswirken. Dadurch ergibt sich ein charakteristisches Modellverhalten, das eher langfristig verzögerte Trainingseffekte approximiert und kurzfristige Leistungsveränderungen nicht erfasst. Das PerPot-Modell eignet sich somit eher für eine näherungsweise Planung der Gesamtbelastung über einen längeren Zeitraum, während das FF-Modell kurzfristige Wechsel im Leistungsverlauf besser darstellen kann (Banister et al., 1999; Brückner, 2006; Ganter et al., 2006).

Die Modellierung von Trainingswirkungen mit neuronalen Netzen ist ein pragmatischer Modellansatz (Hohmann et al., 2000; Perl et al., 2002). Künstliche neuronale Netze sind ein strukturen-entdeckendes Verfahren, mit denen keine kausalen Zusammenhänge aufgeklärt werden können (Backhaus, Erichson, Plinke & Weiber, 2006). Somit sind auch keine Aussagen über zeitliche Beziehungen zwischen dem Trainingsinput und dem Leistungsoutput möglich.

Hierbei ist außerdem zu berücksichtigen, dass Trainingseffekte zum einen in Abhängigkeit von den Trainingsinhalten mit unterschiedlicher zeitlicher Verzögerung eintreten (Hohmann, 1994). Zum anderen werden mit unterschiedlichen Trainingsformen die Funktionssysteme auch in unterschiedlichem Ausmaß angesprochen und es bestehen Wechselwirkungen beim Training unterschiedlicher Leistungsvoraussetzungen. Grundsätzlich nimmt die Vielfalt und Komplexität des Trainings mit der Komplexität der Leistungsstruktur einer Sportart zu. Hieraus ergibt sich eine entscheidende Limitierung des zeitreihenanalytischen Ansatzes und der antagonistischen Trainings-Wirkungs-Modelle: Die Trainingsinhalte müssen zu einer globalen Variable zusammengefasst werden. Damit ist keine Differenzierung der Trainingsinhalte möglich und es ergibt sich zusätzlich das Problem, dass das Training für die Vergleichbarkeit über alle Kategorien hinweg einheitlich zu quantifizieren ist (Hellard et al., 2006; Ganter, 2009). Daher wurden die meisten Arbeiten zur Analyse und Prognose von Trainingswirkungen bisher auch am Beispiel weniger komplexer Sportarten durchgeführt, bei denen die Aggregation zu einer Inputvariable noch vergleichsweise einfach möglich ist.

Es kann überhaupt nicht berücksichtigt werden, dass die Leistungsfähigkeit eines Athleten neben den Trainingsbelastungen auch von psychologischen und sozialen Belastungen abhängig ist (vgl. Kapitel 2.2.3). Busso & Thomas (2006, S. 401) betrachten diese Limitierung ebenfalls kritisch:

„Multifactorial models could provide a better picture of the effects of the various exercises included in the training program. Such a model could consider several inputs acting on

several factors that determine performance.“

In diesem Zusammenhang ergibt sich ein weiterer Vorteil für die Modellierung von Trainingswirkungen mit neuronalen Netzen. Die Arbeiten im Schwimmen (Hohmann et al., 2000; Edelmann-Nusser et al., 2006) und Bogenschießen (Ganter et al., 2009) zeigen, dass der Einfluss des Trainings multivariat in fünf bzw. sechs Kategorien berücksichtigt werden kann. Zudem ist es nicht zwingend nötig, die Trainingsdaten auf eine vergleichbare, dimensionslose Größe zu transformieren. Dennoch wurden auch bei diesem Ansatz außer der Trainingsbelastung keine weiteren unabhängigen Variablen zur Modellierung der Trainingswirkungen eingesetzt.

**Tabelle 2.2:** Übersicht über die Eigenschaften der vorhandenen Trainings-Wirkungs-Modelle.

	statistische Zeitreihenanaly- se	FF-Modell	PerPot-Modell	Neuronale Netze
zeitliche Abhän- gigkeit			X	
Nichtlinearität			X	X
Kausale Interpre- tierbarkeit	X	X	X	
Multivariabilität				X
Überlauffunktion			X	

Im Hochleistungssport oder im Rehabilitationssport besteht durch zu hohe Belastungen im mittelfristigen Leistungsaufbau immer die Gefahr einer Überforderung oder eines Übertrainings (Richardson et al., 2008). Diese Überlastungsreaktion sollte auch als Eigenschaft in Trainings-Wirkungs-Modellen integriert sein. Das FF-Modell kann die Effekte solcher chronischer Anpassungen an zu hohe Belastungen jedoch nicht simulieren. Obwohl jede Belastung im FF-Modell zu einer Zunahme des Fatigueniveaus führt, baut sich dieses unabhängig von seiner Höhe über die Zeit ab. Der negative Effekt der Ermüdung wird aber in jedem Fall durch die langsamer abnehmende Fitness-Komponente überlagert und es stellt sich damit immer eine Leistungszunahme ein.

Fraglich ist, ob mittels bivariater Zeitreihenmodellierung oder neuronaler Netze Überlastungsreaktionen analysiert und prognostiziert werden können. Die Relation zwischen Trainingsinput und Leistungsoutput wird bei beiden Modellansätzen lediglich über die vorhandene Datenbasis hergestellt. Sofern während des Untersuchungszeitraumes keine Leistungsabnahme über einen längeren Zeitraum in Folge überhöhter Trainingsbelastungen beobachtet wird, fehlt die Datengrundlage, um Aussagen über zukünftige Ereignisse treffen zu können.

Die Überlauf-Funktion des PerPot-Metamodells ist eine maßgebliche Komponente, die es erlaubt, den Kollapseeffekt und die umgekehrte U-Funktion darzustellen. Damit ist dieses Modell bisher das einzige,

dass chronische Überlastungsreaktion infolge zu hoher Trainingsbelastungen abbilden kann.

Die Tabelle 2.2 stellt abschließend in einer Übersicht dar, welche Eigenschaften die einzelnen Modelle zur Analyse und Prognose von Trainingswirkungen kennzeichnen.

## 2.5 Künstliche neuronale Netze als alternative Methode zur Analyse und Prognose von Zeitreihen


Künstliche neuronale Netze (KNN) haben sich vor allem in der Ökonomie und Wissenschaft als eine Methode zur Klassifikation von Daten und zur Mustererkennung etabliert (Rojas, 1996; Zell, 2000; Rey & Wender 2008). Zhang et al. (1998) machen anhand von vier Eigenschaften neuronaler Netze deutlich, weswegen sie sich neben der Datenanalyse auch besonders für eine Prognose von Zeitreihen eignen:

1. Häufig ist es bei komplexen Zusammenhängen im Voraus nicht möglich, theoretische Annahmen zu den zugrunde liegenden strukturellen und funktionalen Zusammenhängen aufzustellen. KNN sind datenorientierte Modelle, die anhand von (Daten-) Beispielen lernen und nicht auf Vorannahmen beruhen müssen.
2. Die Lernfähigkeit und die Fähigkeit zur Generalisierung erlaubt es, mit künstlichen neuronalen Netzen von Bekanntem auf Unbekanntes zu schließen. Damit ist die Vorhersage ein ideales Anwendungsfeld KNN.
3. KNN sind universelle Funktionsapproximatoren. Damit sind sie flexibler als statistische oder mathematische Modelle, um bekannte oder unbekannte Relationen zwischen Eingangs- und Ausgangsdaten herzustellen.
4. Künstliche neuronale Netze sind nichtlineare Datenmodelle, die in der Lage sind, ohne Vorwissen Zusammenhänge zwischen Eingabe- und Ausgabe-Variablen herzustellen. Damit sind sie ein allgemeingültiges und flexibles Modell, mit dem besonders bei komplexen, nichtlinearen Systemen Prognosen möglich sind.

Die Idee, KNN für die Vorhersage von Zeitreihen einzusetzen, geht auf eine frühe Arbeit von Hu (Hu, 1964 zit. nach Zhang et al., 1998) zurück. KNN wurden in der Folgezeit vor allem wegen fehlender Trainingsalgorithmen weniger beachtet (Zell, 2000, S. 29-30). Erst mit der Entwicklung des Backpropagation-Verfahrens (Rumelhart, Hinton & Williams, 1986) nahm das Interesse an neuronalen Netzen wieder deutlich zu. Im Zuge dessen konnten Lapedes & Farber (1987) dann auch zeigen, dass KNN für die Modellierung und Vorhersage nichtlinearer Zeitreihen geeignet sind.

### 2.5.1 Das künstliche Neuron als Entscheidungseinheit

In den vierziger und fünfziger Jahren wurden die Grundlagen für neuronale Netze als ein Berechnungsmodell durch die Pionierleistungen von McCulloch und Pitts (1943) sowie Rosenblatt (1958) gelegt. Ein künstliches Neuron ist die strukturbildende Einheit eines neuronalen Netzes. Es ist als ein Element zur Entscheidungsfindung zu betrachten. Die wesentlichen Hauptfunktionen sind die Informationsaufnahmen und -verarbeitung sowie der Übergang zu einer Informationsausgabe (vgl. Abbildung 2.17).



**Abbildung 2.17:** Schema und Informationsverarbeitung eines künstlichen Neurons (Kruse et al., 1991; Zell, 2000; Lämmel & Cleve, 2004). Weitere Erläuterungen zu dieser Abbildung befinden sich im Text.

Ein Neuron  $j$  empfängt als Eingabeinformationen die Ausgabe  $x_i$  vorgeschalteter Neuronen  $i$  im Netz über gewichtete Verbindungen  $w_{i,j}$ . Das Produkt  $x_i \cdot w_{i,j}$  von Ausgabe und Verbindungsgewicht ergibt die Eingabe eines einzelnen Neurons. Die Eingaben aller Neuronen, die mit dem Zielneuron in Verbindung stehen, werden als Nettoinput  $net_j$  in der Propagierungsfunktion aufsummiert (Gleichung 2.16):

$$net_j = \sum_{i=1}^n x_i \cdot w_{i,j} \quad (2.16)$$

Die Informationsverarbeitung ergibt sich aus der Zuordnung des Nettoinputs zur Aktivität  $a_j$  des Neurons in der Aktivierungsfunktion  $f_{act}$  (Formel 2.17):

$$a_j = f_{act}(net_j) \quad (2.17)$$

Je nach Struktur der neuronalen Netze werden unterschiedliche Aktivierungsfunktionen verwendet. Die Aktivierungsfunktion bildet einen linearen Zusammenhang zwischen Nettoinput und Aktivität ab. Die Identitätsfunktion ist eine lineare Aktivierungsfunktion. Sie gibt den Wert der Propagierungsfunktion direkt weiter (Gleichung 2.18). In diesem Fall ist die Aktivierungsfunktion nach unten und oben nicht begrenzt.


$$a_j = f_{act} = net_j \quad (2.18)$$

Für die nichtlineare Entscheidungsmodellierung neuronaler Netze ist es wesentlich, nichtlineare Formalismen in der Modellierung einzuführen. Wenn im Sinne einer Schalterfunktion nur zwei Werte als Ergebnis der Aktivierungsfunktion zugelassen werden sollen, kann eine binäre Schwellwertfunktion eingesetzt werden (vgl. Rey & Wender, 2008, S. 21 - 28).

Die Basis einiger Netzwerkstrukturen sind Lernverfahren, die eine differenzierbare Aktivierungsfunktion voraussetzen. In diesen Fällen werden meist sigmoide Funktion eingesetzt. Die logistische Aktivierungsfunktion nimmt dann Werte zwischen 0 und 1 an. Die Tangens Hyperbolicus (tanh) Aktivierungsfunktion hat den Wertebereich [-1,1]. Bei beiden Funktionen verändert der Parameter  $c$  die Steilheit der Kurve (vgl. Gleichungen 2.19 und 2.20 sowie Abbildung 2.18). Je größer  $c$  ist, desto mehr nähert sich die Funktion der binären Schwellwertfunktion an und desto kleiner müssen die Änderungen sein, um Extremwerte der Sigmoidfunktion anzunehmen.

$$f_{logistic}(x) = \frac{1}{1 + e^{-c \cdot x}} \quad (2.19)$$

$$f_{tanh}(x) = \tanh(c \cdot x) \quad (2.20)$$



**Abbildung 2.18:** Logistische und tanh-Aktivierungsfunktion. Der Parameter  $c$  beeinflusst die Steilheit der Kurve (Zell, 2000; Lämmel & Cleve, 2004).

Die Ausgabe  $x_j$  des Neurons definiert sich über dessen Aktivität. In der Regel wird der Ausgangszustand dem inneren Aktivierungszustand gleichgesetzt:

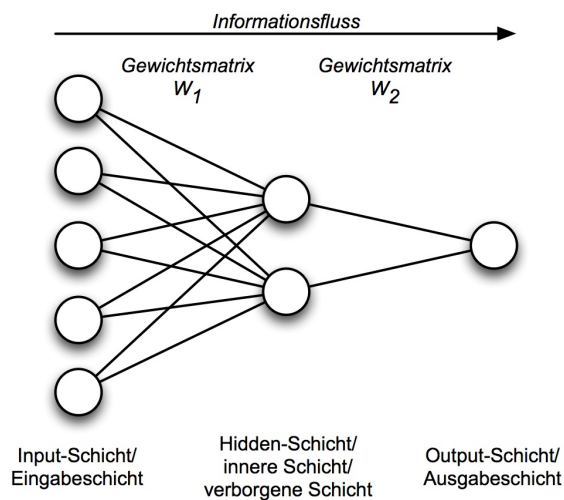
$$x_j = f_{out}(a_j) = a_j \quad (2.21)$$

### 2.5.2 Künstliche neuronale Netze

Künstliche neuronale Netze bestehen aus miteinander verbundenen künstlichen Neuronen. Zu Beginn der Entwicklung stand die Nachbildung des biologischen Vorbildes im Vordergrund. In der Folge wurden dann aber auch die Möglichkeiten für die Abstraktion von Prozessen der Informationsverarbeitung

erkannt. Neuronale Netze grenzen sich von herkömmlichen algorithmischen Modellen dadurch ab, dass im Voraus lediglich die Netzstruktur und das Lernverfahren festzulegen sind. Die funktionalen und strukturellen Zusammenhänge eines Problems müssen nicht bekannt sein, um sie in einem Programm abzubilden. Das Netz erwirbt in einem Lernprozess die richtige Konfiguration selbständig. Diese Form der Datenverarbeitung macht KNN zu einem leistungsfähigen Berechnungsverfahren, das anhand von Beispielen lernt und für unbekannte Daten generalisieren kann (Rojas, 1996; Zell, 2000; Rey & Wender, 2008).

Durch die Verknüpfung mehrerer Neuronen zu einem Netz entsteht ein Modell mit Wechselwirkungen zwischen vielen Entscheidungen. Eine einfache Netzstruktur oder Netzwerktopologie entsteht, wenn man die Neuronen zu einem mehrschichtigen Netzwerk kombiniert. Dieser Netztyp wird als Multilayer Perceptron (MLP) bezeichnet (vgl. Abbildung 2.19).



**Abbildung 2.19:** Das neuronale Netz als überlagerte Entscheidungsstruktur. Das dargestellte MLP besteht aus einer vollständig verknüpften Eingabeschicht, einer verborgenen Schicht und einer Ausgabeschicht.

Die Eingabeschicht (Input Schicht) setzt sich aus allen Eingabeneuronen zusammen. Diese sind dadurch gekennzeichnet, dass sie keine Eingabe über gewichtete Verbindungen  $w_{i,j}$  anderer Neuronen erhalten. Im Sinne eines Prozesses zur Entscheidungsfindung ist es deren Aufgabe, Informationen aufzunehmen und an die nachfolgenden Entscheidungsstrukturen weiter zu geben. In diesen weiteren Schichten findet in jeder Zelle die Informationsverarbeitung statt, wie sie in Kapitel 2.5.1 beschrieben wurde. Die Ausgabe der Neuronen dieser inneren Schicht, dient den folgenden Schichten wiederum als Eingabe. Dieses strukturelle Prinzip kann beliebig fortgesetzt werden. Durch die unterschiedlichen Gewichte der Verbindungen nimmt jedes Neuron der inneren Schichten eine andere Filterung der Eingangsinformationen vor und betrachtet so jeweils eine andere Facette der Datenzusammenhänge. Die letzte Schicht steht mit keinen nachfolgenden Neuronen in Verbindung und gibt die Ausgabe des Netzes wieder. Da der Informationsfluss in diesen Netzen nur in eine Richtung läuft, werden solche Netze auch als Feed-Forward-Netze bezeichnet. Andere Topologien sind für das weitere Verständnis

dieser Arbeit nicht relevant, werden aber bspw. bei Rojas (1996), Zell (2000) sowie Rey & Wender (2008) detailliert diskutiert.

Bei der Arbeitsweise neuronaler Netze muss zwischen trainierbaren und nicht trainierbaren Netzen unterschieden werden (vgl. im Überblick Zell, 2000). Trainierbarkeit bedeutet, dass ein Netz die Informationen einer Eingabe selbständig zu einer Ausgabe verarbeitet. Die Lernverfahren werden weiter in überwachte, bestärkende und nicht überwachte Verfahren unterteilt. Für den überwachten Lernprozess wird sowohl die Eingabe als auch die zu erwartende Ausgabe des Netzes benötigt. Hierfür muss ein entsprechender Datensatz mit Paaren von Eingabe- und Zielwerten vorliegen. Mit den Abweichung zwischen dem Netzoutput und den Zielwerten wird die interne Netzstruktur, respektive die Verbindungsgewichte, so verändert, dass am Ende des Lernverfahrens das Netz eine Dateneingabe zu einer korrekten Ausgabe verarbeitet. Ausführliche Beschreibungen der bestärkenden und nicht überwachten Lernalgorithmen finden sich bei Ritter, Martinetz und Schulten (1991) sowie Zell (2000).

Besteht ein Feed-Forward-Netz lediglich aus einer Eingabe- und einer Ausgabeschicht (sog. Perzeptron), kommt die Delta-Lernregel für das Netztraining zur Anwendung (Rey & Wender, 2008, S. 40 - 42). Da es ausschließlich Verbindungen gibt, die auf Ausgabeneuronen projizieren, kann die Abweichungen zwischen der Netzausgabe und den Zielwerten genutzt werden, alle Verbindungsgewichte anzupassen. Bei einem MLP ist die Delta-Regel nicht mehr als Lernverfahren anwendbar, da für die Neuronen der inneren Schichten keine Trainingsausgaben vorliegen. Für diesen Fall wurde der bekannte Backpropagation-Trainingsalgorithmus entwickelt (Rumelhart, Hinton & Williams, 1986):

„Das Backpropagation-Verfahren ist ein Verfahren des überwachten Lernens zum Anpassen der Verbindungsgewichte. Die Gewichtsänderung erfolgt ausgehend von einem aus der Abweichung der berechneten Ausgabe von der erwarteten Ausgabe bestimmten Fehler-signal. Die Gewichtsänderung wird schichtenweise, beginnend mit den Verbindungen zur Ausgabeschicht rückwärts in Richtung Eingabeschicht, vorgenommen" (Lämmel & Cleve, 2004, 192).

In den meisten konkreten Anwendungsproblemen, wie auch in der Analyse und Prognose von Zeitreihen wird auf das Backpropagation-Verfahren als Trainingsalgorithmus zurück gegriffen. Eine übersichtliche Herleitung des Verfahrens wird von Lämmel & Cleve (2004, S. 192 - 195) beschrieben. Entscheidend für den Lernvorgang des Netzes ist es, die Verbindungsgewichte so anzupassen, dass die Fehlerfunktion ein Minimum annimmt. Wie bereits erwähnt wurde, liegt bei einem MLP für die Neuronen der inneren Schicht keine Trainingsausgabe  $t_j$  zur Ermittlung des Fehlers vor. Der Fehler der Ausgabeschicht muss zu den inneren Schichten zurück geleitet werden. D.h. es wird zuerst der Fehler der Ausgabeschicht bestimmt. Dann können, entgegen der Richtung der Informationsverarbeitung, die Fehler der inneren Schichten zur Gewichtsveränderung sukzessive berechnet werden. Diesem Vorgehen entsprechend ändert das online Trainingsverfahren die Verbindungsgewichte nach jedem einzelnen Trainingsmuster. Der Backpropagation-Lernalgorithmus sucht immer möglichst das globale Minimum der Fehlerfunktion. Im mehrdimensionalen Fall vielfach verknüpfter Netze werden zur Fehlerminimierung Gradienten-

tenabstiegsverfahren eingesetzt. Die Richtung der stärksten Steigung ist die Gradientenrichtung. Als Lösung des Lernproblems wird diejenige Kombination von Verbindungsgewichten angenommen, die den Berechnungsfehler minimiert. Daher muss für alle Punkte des Gewichtraums der Gradient der Fehlerfunktion vorliegen, d.h. es müssen die partiellen Ableitungen der Fehlerfunktion nach den einzelnen Gewichten überall definiert sein (Rojas, 1996). Hierfür muss die Schwellwertfunktion stetig und differenzierbar sein (vgl. 2.5.1). Der Fehler oder das Fehlersignal  $\delta$  lässt sich mit der Gleichung 2.22 unter Verwendung der logistischen Funktion als Aktivierungsfunktion ermitteln:

$$\delta_j = \begin{cases} x_j \cdot (1 - x_j) \cdot (t_j - x_j), & \text{falls } j \text{ Ausgabe-Neuron} \\ x_j \cdot (1 - x_j) \cdot \sum \delta_k \cdot w_{j,k}, & \text{falls } j \text{ inneres Neuron} \end{cases} \quad (2.22)$$

In der Gleichung 2.22 gibt der Ausdruck  $\sum \delta_k \cdot w_{j,k}$  die Summe aller Produkte der Fehlersignale und der Verbindungsgewichte wieder, mit denen das innere Neuron verbunden ist.

Mit dem Fehlersignal kann schließlich die Änderung  $\Delta w_{i,j}$  der Verbindungsgewichte berechnet werden. Zur Steuerung der Geschwindigkeit des Lernprozesses wird ein Lernfaktor  $\eta$  eingefügt:

$$\Delta w_{i,j} = \eta \cdot x_i \cdot \delta_j \quad (2.23)$$

Somit gilt für das veränderte Gewicht  $w_{i,j}(t + 1)$ :

$$w_{i,j}(t + 1) = w_{i,j}(t) + \Delta w_{i,j} = w_{i,j}(t) + \eta \cdot x_i \cdot \delta_j \quad (2.24)$$

Da das Gradientenabstiegsverfahren ein lokales Verfahren ist, sind mit dem Backpropagation-Verfahren einige Probleme verbunden. Die Suche nach einem Minimum erfolgt immer nur anhand der Informationen über eine begrenzte Umgebung. Das Verfahren kann somit in einem lokalen Minimum stehen bleiben und möglicherweise nicht das globale Minimum der gesamten Fehlerfläche finden. Zudem nimmt der Trainingsprozess sehr viel Zeit in Anspruch, wenn die Fehlerkurve sehr flach und der Anstieg betragsmäßig sehr klein ist. Damit ist auch die Gewichtsänderung betragsmäßig sehr klein und die Verbindungsgewichte ändern sich nur wenig.

Ist die Fehlerkurve hingegen sehr steil, d.h. der Anstieg sehr hoch, kann es dazu kommen, dass die Gewichtswerte um eine Minimum herum schwingen und sich nicht auf dieses Minimum einpendeln. Schließlich kann es noch vorkommen, dass bei besonders engen Tälern der Fehlerfläche der Betrag des Gradienten besonders groß ist. In diesem Fall kann die Gewichtsänderung aus einem guten Minimum in ein anderes, suboptimales Minimum führen (Lämmel & Cleve, 2004, S. 203).

Es werden einige Varianten des Backpropagation-Verfahrens vorgeschlagen, um die aufgeführten Probleme zu vermeiden (Rojas, 1996, S. 168 - 172; Zell, 2000, S. 115 - 126; Lämmel & Cleve, 2004, S. 203 - 204). Für die Analyse und Prognose von Zeitreihen wurden hiervon meist das Backpropagation mit Momentum (BPM-Verfahren) und das Resilient Propagation (RPROP-Verfahren) eingesetzt (Thiesing, 1998; Zhang et al., 1998). Daher werden diese Verfahren noch etwas näher erläutert.

Für das Backpropagation mit Momentum wird die vorherige Gewichtsänderung  $\Delta w_{ij}(t - 1)$  einbezogen. Ein weiterer Faktor  $\mu$  im Wertebereich zwischen 0 und 1 kontrolliert den Anteil dieser



Veränderung. Die Gewichtsänderung zum Zeitpunkt  $t$  (vgl. 2.23) ändert sich dadurch wie folgt:

$$\Delta w_{i,j} = \eta \cdot x_i \cdot \delta_j + \mu \cdot \Delta w_{i,j}(t-1) \quad (2.25)$$

Das offline RPROP-Verfahren ändert die Verbindungsgewichte nicht entsprechend des Betrags des Gradienten aus der Fehlerfunktion, sondern bezieht nur die Vorzeichen des Gradienten ein. Dazu werden die Steigungen der Fehlerfunktion des aktuellen Zeitpunkts  $t$  und des vorherigen Zeitpunkts  $t-1$  berücksichtigt. Der Betrag der Gewichtsänderung wird in diesem Fall mit  $\Delta_{ij}(t)$  und die Änderung eines Gewichts  $w_{ij}(t)$  mit  $\Delta w_{ij}(t)$  bezeichnet und auch getrennt verändert.

$$\Delta_{ij}(t) = \begin{cases} \Delta_{ij}(t-1) \cdot \eta^+ & \text{falls } S(t-1)S(t) > 0, \\ \Delta_{ij}(t-1) \cdot \eta^- & \text{falls } S(t-1)S(t) < 0, \\ \Delta_{ij}(t-1) & \text{sonst.} \end{cases} \quad (2.26)$$

Für die Parameter  $\eta^+$  und  $\eta^-$  gilt:  $0 < \eta^- < 1 < \eta^+$ . Häufig werden hierfür die Werte  $\eta^- = 0,5$  und  $\eta^+ = 1,2$  eingesetzt, da diese sich in mehreren Testbeispielen bewährt haben (Zell, 2000, S. 126).  $S(t)$  ist die Ableitung der Fehlerfunktion zum Zeitpunkt  $t$ .

Die Gewichtsänderung hängt dann vom Vorzeichen der Steigung zum aktuellen und zum vorherigen Zeitpunkt ab. Die Gleichungen der Gewichtsänderung  $\Delta w_{ij}(t)$  und der Gewichte  $w_{ij}(t+1)$  lauten:

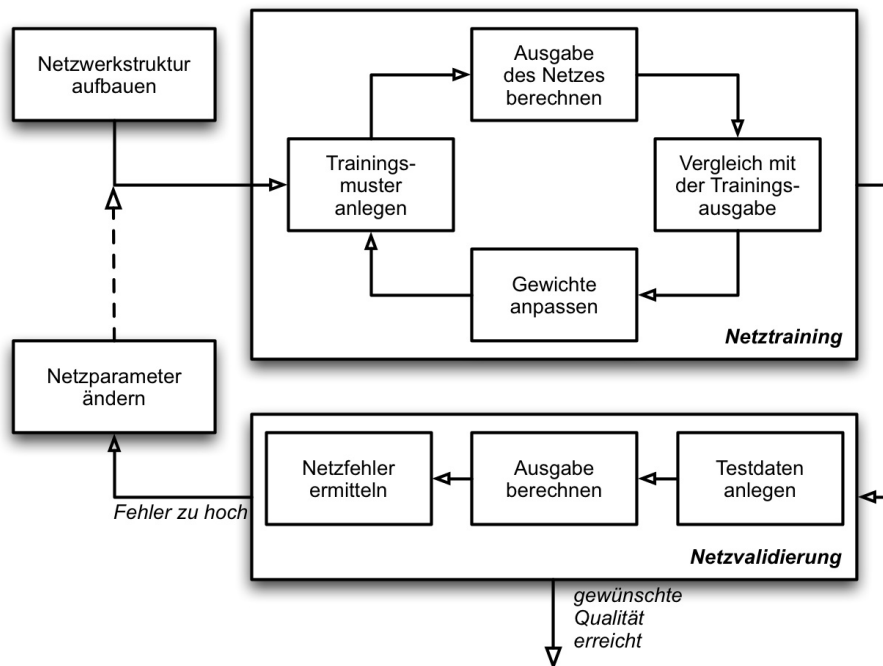
$$\Delta w_{ij}(t) = \begin{cases} -\Delta w_{ij}(t-1) & \text{falls } S(t-1)S(t) > 0 \wedge S(t) > 0, \\ \Delta w_{ij}(t) & \text{falls } S(t-1)S(t) > 0 \wedge S(t) < 0, \\ -\Delta w_{ij}(t-1) & \text{falls } S(t-1)S(t) < 0, \\ -\text{sgn}(S(t))\Delta_{ij}(t) & \text{sonst.} \end{cases} \quad (2.27)$$

$$w_{i,j}(t+1) = w_{ij}(t) + \Delta w_{ij}(t). \quad (2.28)$$

Im dritten Fall der Gewichtsänderung (vgl. Gleichung 2.27) wird  $S(t) = 0$  angenommen, um ein Hin- und Herschwingen der Gewichtsänderung zu vermeiden. Ergänzend werden Schranken  $\Delta_{min}$  und  $\Delta_{max}$  gesetzt, die den Betrag der Gewichtsänderung beschränken.

Die Abbildung 2.20 veranschaulicht das wesentliche Vorgehen bei der Entwicklung trainierbarer KNN. Im ersten Schritt ist auf der Grundlage des zu lösenden Problems die Topologie festzulegen. Zum einen wird die Netzstruktur mit der Anzahl der Neuronen, der Anzahl der Schichten und die Form und Anzahl der Verbindungen aufgebaut. Zum anderen sind die Art der Initialisierung, die Aktivierungsfunktion, der Trainingsalgorithmus und die Lernparameter zu definieren. Im nächsten Schritt wird der gesamte Datensatz in Trainings- und Testdaten aufgeteilt. Sowohl für die Trainings- als auch für die Testdaten muss jeweils das Eingabemuster und die Ausgabe bekannt sein.

Für die weitere Verarbeitung werden die Daten i.d.R. normiert. Die Art und Weise der Datennormierung ist von den Eingabedaten und der Aktivierungsfunktion abhängig. Bei Eingabedaten, die eine



**Abbildung 2.20:** Schema der Arbeitsschritte zur Entwicklung eines künstlichen neuronalen Netzes (mod. nach Lämmel & Cleve, 2004).

einheitliche Skalierung aufweisen, kann auch eine einheitliche Normalisierung vorgenommen werden. Gibt es hingegen große Unterschiede in der Skalierung einzelner Inputvariablen, bietet sich eine getrennte Normierung jeder einzelnen Variable an. Die nichtlinearen Aktivierungsfunktionen geben eine Ausgabe im Bereich  $[-1, 1]$  und  $[0, 1]$  weiter. Sobald eine dieser Funktionen in der Ausgabeschicht eingesetzt wird, ist zumindest die Netzausgabe für die Fehlerberechnung verschiedener Trainingsalgorithmen (z.B. Backpropagation) auf den selben Wertebereich zu normieren. Um Berechnungsprobleme zu vermeiden, ist es generell von Vorteil, alle Ein- und Ausgabedaten einheitlich zu skalieren (Lapedes & Farber, 1987).

Mit den Trainingsdaten lernt das Netz mithilfe des definierten Trainingsalgorithmus. Bei der Netzvalidierung wird überprüft, wie gut das Netz die vorgegebene Aufgabe erfüllt, d.h. wie gut die Generalisierungsfähigkeit eines Netzes ist. Hierfür werden dem Netz die unbekannt Testdaten präsentiert und die entsprechenden Ausgaben berechnet. Schließlich wird der Netz- oder Generalisierungsfehler als Abweichung zwischen der Netzausgabe und der erwarteten Ausgabe bestimmt. Sofern die gewünschte Qualität erreicht wird, kann das Netz für seine spezifische Aufgabe eingesetzt werden. Ist der Fehler der Validierung zu groß, müssen in einem iterativen Prozess die Netzparameter solange geändert werden, bis ein akzeptables Ergebnis erreicht wird.

Eine Trennung in Trainings- und Testdaten ist aber nur dann möglich, wenn die gesamte Datenmenge ausreichend groß ist. Eine Richtlinie geht von mindestens doppelt so vielen Datensätzen wie Verbindungen für das Netztraining aus. Für die Größe des Testdatensatzes sind auch nur wenige und

uneinheitliche Vorgaben vorhanden (Zhang et al., 1998). Die meisten Angaben beziehen sich auf bestimmte Verhältnisse (z.B. 90 % zu 10 % oder 80 % zu 20 %). Wenn die Datenmenge begrenzt ist und möglichst alle Datensätze  $M_1, M_2, \dots, M_n$  für das Netztraining benötigt werden, ist es möglich, den Testdatensatz durch die Leave-One-Out-Methode zu erhöhen. Hierbei wird schrittweise jeweils ein Datensatz als Testdatensatz aus der gesamten Datenmenge heraus genommen (Edelmann-Nusser et al., 2002). Die Validierung des Netzes erfolgt damit nach folgendem Schema:

- **Validierungsdurchgang 1**  
Netztraining mit Datensätzen  $M_2 - M_n$   
Netzvalidierung mit Datensatz  $M_1$
- **Validierungsdurchgang 2**  
Netztraining mit Datensätzen  $M_1, M_3 - M_n$   
Netzvalidierung mit Datensatz  $M_2$
- ...
- **Validierungsdurchgang n**  
Netztraining mit Datensätzen  $M_1 - M_{n-1}$   
Netzvalidierung mit Datensatz  $M_n$

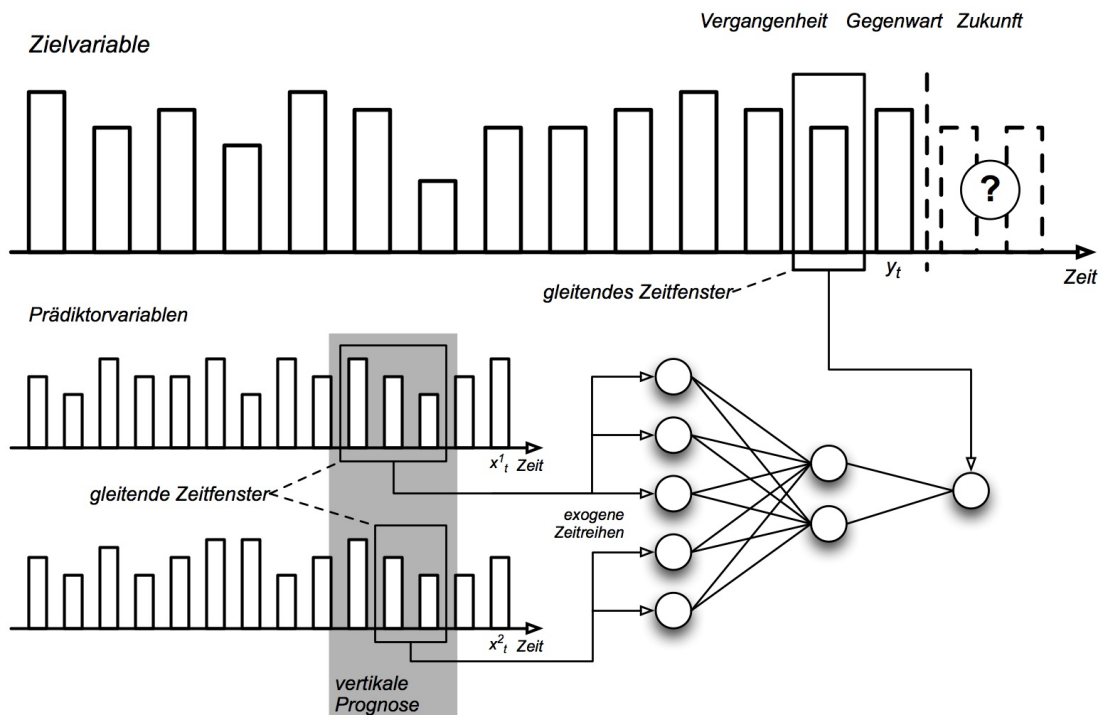
### 2.5.3 Anwendung künstlicher neuronaler Netze zur Analyse- und Prognose von Zeitreihen

Werden künstliche neuronale Netze zur Analyse- und Prognose von Zeitreihen eingesetzt, bilden unabhängige bzw. Prädiktorvariablen den Netzinput. Ziel ist es, mit einer Kombination von  $n$  aufeinanderfolgenden Werten  $x_t, x_{t-1}, x_{t-2}, \dots, x_{t-n}$  der Prädiktorvariable den Wert  $y_{t+1}$  der abhängigen bzw. Zielvariable vorherzusagen. Der funktionale Zusammenhang, der mit KNN abgeschätzt wird, lässt sich wie folgt beschreiben:

$$y_{t+1} = f(x_t, x_{t-1}, x_{t-2}, \dots, x_{t-n}) \quad (2.29)$$

Damit ist das neuronale Netz funktionell mit einem nichtlinearen Regressionsmodell vergleichbar (Rojas, 1996; Thiesing, 1998; Zhang et al., 1998; Zell, 2000).


Aus einem gleitenden Zeitfenster der Breite  $n$  ergeben sich alle Kombinationen von  $n$  aufeinanderfolgenden Werten einer unabhängigen Variable. Es können auch mehrere Variablen unterschiedlicher zeitlicher Tiefe berücksichtigt werden. Das Netztraining erfolgt mit allen Eingabemustern und der entsprechenden abhängigen Variable als Netzausgabe. Nachdem das Netz trainiert wurde, wird für die Prognose der Zielvariable zum Zeitpunkt  $t + 1$  das letzte bekannte Muster als Eingabe dem Netz präsentiert. Die berechnete Netzausgabe ergibt dann den Prognosewert der abhängigen Variable  $y_{t+1}$  (vgl. Abbildung 2.21). Der funktionale Zusammenhang wird in diesem Fall zwischen einer oder meh-



**Abbildung 2.21:** Analyse und Prognose von Zeitreihen mit künstlichen neuronalen Netzen anhand exogener Zeitreihen (vertikale Prognose). Aus den gleitenden Zeitfenstern ergeben sich alle Muster für das Netztraining (mod. nach Thiesing, 1998).

renen exogenen Zeitreihen und der Zielvariable hergestellt. Man spricht in diesem Fall auch von einer vertikalen Prognose. Diese Modellstruktur kann zudem durch eine autoregressive Komponente ergänzt werden, indem zusätzlich eine Abhängigkeit der Zielvariable von deren Verlauf integriert wird. D.h. der Wert der abhängigen Variable  $y$  zum Zeitpunkt  $t + 1$  ist durch frühere Werte derselben Variable  $y_t, y_{t-1}, y_{t-2}, \dots, y_{t-n}$  (endogene Zeitreihe) bestimmt. Dies wird auch als horizontale Prognose bezeichnet (vgl. Abbildung 2.22).

Zhang et al. (1998), Hippert et al. (2001) und Eisenbach (2005) zeigen in umfangreichen Literaturstudien Anwendungsfelder KNN zur Analyse und Prognose von Zeitreihen auf. Sehr viele Arbeiten lassen sich dem Bereich der Ökonomie und Finanzwirtschaft zuordnen. Ein weiteres großes Anwendungsgebiet ist die Zeitreihenanalyse in den Ingenieurwissenschaften und in der Physik. In der Medizin kamen KNN zur Analyse und Prognose von Zeitreihen bisher nur selten zur Anwendung. Bei einer eigenen Literaturrecherche in den wissenschaftlichen Zeitschriften Journal of Forecasting, Neural Networks und Neurocomputing sowie in der medizinischen Literaturdatenbank pubmed im Zeitraum von 2000 - 2010 wurden lediglich sieben Arbeiten gefunden (Petrosian et al., 2000; Panerei et al., 2004; Shieh et al., 2004; Yang et al., 2005; Manis et al., 2007; Goodband et al., 2008; Petrović et al., 2009). In der Sport- und Bewegungswissenschaft ist bisher keine Arbeit bekannt, in der KNN für die Analyse und Prognose von Zeitreihen eingesetzt wurden.



**Abbildung 2.22:** Analyse und Prognose von Zeitreihen mit künstlichen neuronalen Netzen anhand exogener und endogener Zeitreihen (vertikale und horizontale Prognose). Aus den gleitenden Zeitfenstern ergeben sich alle Muster für das Netztraining (mod. nach Thiesing, 1998).

#### 2.5.4 Topologie künstlicher neuronaler Netze zur Analyse und Prognose von Zeitreihen

Ebenfalls sehr ausführlich stellen Zhang et al. (1998), Hippert et al. (2001) und Eisenbach (2005) in ihren Übersichtsarbeiten die wesentlichen Merkmale der Topologie von KNN als Prognosemodelle dar. Demnach werden vornehmlich MLPs mit 1 oder 2 verdeckten Schichten eingesetzt, die vollständig vorwärts verknüpft sind. Eher selten sind Rückkopplungen innerhalb der Netze zu finden. Die Anzahl der Eingabeneuronen ist immer von der Fragestellung abhängig. Es werden aber kaum mehr als 20 Eingabeneuronen verwendet. Da in den meisten Fällen nur ein Wert prognostiziert wird, besteht die Ausgabeschicht auch weitgehend lediglich aus einem Neuron. Die Zahl der Neuronen in den verborgenen Schichten ist einerseits von der Zahl der Eingabeneuronen und andererseits von der Komplexität der Aufgabenstellung abhängig. Moshiri und Cameron (2000) besprechen verschiedene Berechnungsverfahren der Neuronanzahl in verdeckten Schichten, die allerdings sehr unterschiedliche Ergebnisse liefern. Grundsätzlich sollte die Komplexität eines neuronalen Netzes aber möglichst gering sein.

In vielen Anwendungsfällen wird der Vorteil KNN genutzt, nichtlineare Zusammenhänge abbilden zu können, weswegen am häufigsten sigmoide Aktivierungsfunktionen sowohl in den verborgenen Schichten als auch in der Ausgabeschicht zum Einsatz kommen (vgl. Kapitel 2.5.1). Diese Funktionen erfüllen auch die Anforderung der Differenzierbarkeit, die Voraussetzung für das Backpropagation-Lernverfahren und den davon abgeleiteten Varianten ist. In Kapitel 2.5.2 wurde bereits deutlich gemacht, dass sich bei der Analyse und Prognose von Zeitreihen mit KNN das Backpropagation mit Momentum und das RPROP-Verfahren als Trainingsalgorithmus etabliert haben. Damit umgeht man die bekannten Probleme des Backpropagation-Verfahrens.

Bisher gibt es kein anerkanntes Verfahren, mit dem die Werte der Lernrate und der Konstanten eines Lernverfahrens zu bestimmen sind. Die Suche nach geeigneten Werten wird dadurch erschwert, dass diese im Wertebereich  $[0,1]$  frei definiert werden können und somit die Anzahl der Kombinationsmöglichkeiten gegen unendlich geht. Sharda und Patil (1992) schlagen daher vor, immer nur eine begrenzte Kombination von Werten in Betracht zu ziehen.

Die Netzentwicklung setzt weiterhin voraus, dass ein Verfahren zur Datennormalisierung definiert wird. Da in den meisten Fällen sigmoide Aktivierungsfunktionen zum Einsatz kommen, bietet sich eine lineare Transformation der Ein- und Ausgabedaten auf den entsprechenden Wertebereich dieser Funktionen an. Zhang et al. (1998, S. 49) schlagen zudem vor, bei der Analyse und Prognose kausaler Zusammenhänge jeder Inputvariable getrennt zu normieren:

- lineare Transformation auf  $[0,1]$ :  $x_n = \frac{x_0 - x_{min}}{x_{max} - x_{min}}$ ,
- lineare Transformation auf  $[a,b]$ :  $x_n = (b - a) \frac{x_0 - x_{min}}{x_{max} - x_{min}} + a$ .

Für den besonderen Anwendungsfall der Analyse und Prognose von Zeitreihen mit KNN machen Zhang et al. (1998, S. 50-51) keine spezifischen Angaben zur Zahl der Datenstichprobe. Sie verweisen lediglich darauf, dass die Stichprobe möglichst groß sein sollte, dies aber immer von den Möglichkeiten der Datenerhebung abhängig ist. Zum Verhältnis von Trainings- zu Testdaten geben sie an, dass einige Autoren empfehlen, mindestens 20 % für die Netzvalidierung zurück zu halten.

### 2.5.5 Kritische Analyse der Prognoseleistung künstlicher neuronaler Netze

Adya & Collopy (1998) konnten bei einer umfangreichen Literaturrecherche feststellen, dass bei 86 % der berücksichtigten Arbeiten die Vorhersage ökonomischer Zeitreihen mit KNN alternativen Methoden überlegen ist. Auch Zhang et al. (1998) zeigen mit ihrer Literaturanalyse, dass KNN in den meisten Fällen bessere Ergebnisse liefern als andere Methoden zur Zeitreihenanalyse und- prognose. Sie verweisen darauf, dass die Überlegenheit besonders dann deutlich wird, wenn kürzere Zeiträume analysiert werden. Damit liegen i.d.R. auch Zeitreihen mit größerer Messhäufigkeit vor, weswegen Unregelmäßigkeiten wie Saisonalität, Nichtlinearität oder Rauschen deutlicher werden. Der Vorteil liegt darin, dass in solchen Daten mit KNN die zugrunde liegende Muster besser erkannt werden.

Dennoch führen Zhang et al. (1998) sowie Adya und Collopy (1998) einige Studien an, bei denen KNN

anderen Verfahren leistungsmäßig nicht überlegen sind. Hippert et al. (2001, S. 53) sehen die Ursache hierfür vor allem in methodischen Schwierigkeiten. Neben der Netzwerkstruktur, dem Trainingsalgorithmus und den Trainingsdaten wirken sich u.a. mehrere Netzparameter auf die Abbildungsleistung neuronaler Netze aus. Damit hat bereits die Netzentwicklung einen entscheidenden Einfluss auf die Ergebnisse der Modellierung mit neuronalen Netzen. In einigen Fällen liegt die Prognoseleistung von KNN unter der Leistung linearer Methoden. Nach Zhang et al. (1998, S. 52) ist dies darauf zurück zu führen, dass bessere Ergebnisse mit KNN auch nicht zu erwarten sind, wenn für die Analyse und Prognose linearer Zusammenhänge geeignete lineare Modelle eingesetzt werden können.

Bisher ist somit nicht eindeutig geklärt, dass KNN anderen Methoden bei der Analyse und Prognose von Zeitreihen überlegen sind. Solange sind die Ergebnisse mit anderen anerkannten Methoden zu vergleichen, um im speziellen Anwendungsfall eine Bewertung der Prognoseleistung vornehmen zu können (Adya & Collopy, 1998).

# Kapitel 3

## Problem- und Fragestellung


Der Forschungsstand zeigt, dass die Komplexität des Gegenstandsbereichs Training mit den aktuellen Modellen des Trainings und der Trainingssteuerung nicht adäquat bearbeitet werden kann. Allgemeine Zustimmung findet der forschungsstrategische Zugang, das Training mit intensiven Ansätzen wissenschaftlich zu fundieren. Die wesentliche Kritik richtet sich gegen die theoretischen Modelle, die den Trainingsprozess nicht vollständig beschreiben können. In den Fokus sind daher vermehrt integrative Ansätze gerückt, die die Komplexität und Dynamik des Trainings abbilden. Auf der Grundlage des bestehenden Forschungsdefizits wurde ein eigenes systemdynamisches Modell des Trainings entwickelt.

Darüber hinaus sind Defizite bei den Planungs- und Steuerungsstrategien erkennbar. Eine zunehmende Bedeutung haben simulative Trainings-Wirkungs-Modelle für die individuelle Steuerung von Trainingsprozessen erlangt. Bei den vorhandenen Modellen wurden aber entscheidende Vereinfachungen vorgenommen, aus denen sich ebenfalls eine eingeschränkte Vereinbarkeit mit der Komplexität und Dynamik des Trainingsprozesses ergibt. Bislang fehlt hierfür ein Ansatz, der aus dem systemdynamischen Modell des Trainings abgeleitet ist und gleichzeitig das komplexe und dynamische Geschehen der Leistungsentwicklung berücksichtigt.

Im Forschungsstand wurde darüber hinaus ausführlich dargestellt, dass künstliche neuronale Netze eine alternative Methode zur Analyse und Prognose von Zeitreihen sind. Wegen Ihrer spezifischen Eigenschaften eignen sich KNN besonders, nichtlineare und multikausale Relationen darzustellen, sodass sich ihr Einsatz für eine simulative Trainings-Wirkungs-Modellierung in Sportarten mit komplexer Leistungsstruktur anbietet.

Ziel dieser Arbeit ist es, unter der Annahme des systemdynamischen Modells des Trainings den Zusammenhang zwischen Beanspruchung und sportlicher Leistungsfähigkeit mit künstlichen neuronalen Netzen verlaufsorientiert abzubilden und die Leistungsentwicklung vorherzusagen. Dieser Modellvorstellung zufolge löst der aktuelle Beanspruchungszustand als Kontrollparameter Veränderungen der Leistungsfähigkeit aus. Der Beanspruchungszustand ergibt sich aus der Wechselwirkungen zwischen Erholungsmaßnahmen und physischen, psychischen sowie sozialen Belastungen. Daher werden differenziert trainingsinduzierte Beanspruchungen und der psychometrisch erfasste Erholungs- und Bean-





**Abbildung 3.1:** Grundlegende Struktur eines Modells zur Analyse und Prognose von Trainingswirkungen mit künstlichen neuronalen Netzen.

spruchungszustand als Prädiktorvariablen berücksichtigt. Aus der zeitlichen Veränderung des Systems resultiert die Dynamik des Trainingsprozesses. Folglich erklärt sich die Leistungsentwicklung zum Teil auch durch den Leistungsverlauf selbst. In diesem Trainings-Wirkungs-Modell wird daher die Entwicklung der Leistungsfähigkeit als autoregressive Komponente integriert.

Abbildung 3.1 veranschaulicht die grundlegende Modellstruktur des hier vorgestellten Ansatzes zur Analyse und Prognose von Trainingswirkungen. Die Modellgüte und Prognoseleistung dieses Modellierungsansatzes wird im Vergleich zu den antagonistischen Modellen bewertet.

Aus der Zielsetzung dieser Arbeit leiten sich folgende Fragestellungen ab:

### Fragestellung 1

Nimmt die Modellgüte und Prognoseleistung des Trainings-Wirkungs-Modells auf der Basis künstlicher neuronaler Netze zu, wenn die Modellkomplexität durch die differenzierte Betrachtung trainingsinduzierter Beanspruchungen sowie dem aktuellen Erholungs- und Beanspruchungszustand als Prädiktorvariablen erhöht wird?

**Fragestellung 2**

Ergeben sich aus der Zunahme der Modellkomplexität Hinweise, die das theoretische Konzept des systemdynamischen Modells des Trainings stützen?

**Fragestellung 3**

Ist die Abbildungs- und Prognoseleistung eines multivariaten Trainings-Wirkungs-Modells auf der Basis künstlicher neuronaler Netze bivariaten Modellen (Fitness-Fatigue-Modell und Performance Potential Modell) überlegen?

**Fragestellung 4**

Stützt der Vergleich von linearen und nichtlinearen Trainings-Wirkungs-Modellen die Annahme eines komplexen und dynamischen Verhaltens der Leistungsentwicklung?

# Kapitel 4


## Material und Methoden der empirischen Einzelfallanalysen

### 4.1 Forschungszugang und Studiendesign

Die Prüfung der Forschungsfragen erfolgt auf der Basis eines intensiven und prozessanalytischen Untersuchungsansatzes im Triathlon. Hierfür sind zunächst sowohl die Input- als auch die Outputgrößen aus der Leistungs- und Trainingsstruktur für die Modellierung von Trainingswirkungen im Triathlon abzuleiten. Die Wettkampfleistung im Triathlon ist unmittelbar durch die Leistungsfähigkeit in den einzelnen Teildisziplinen determiniert. Dabei sind im besonderen die Disziplinen Radfahren und Laufen leistungsrelevant (Ansley, 2007; Fröhlich, Klein, Pieter & Emrich, 2008). Auf der Ebene der Leistungsvoraussetzungen ist die maximale Sauerstoffaufnahme ( $VO_2\text{max}$ ) neben weiteren submaximalen Größen leistungsbestimmend (Sleivert & Rowlands, 1996; Schabort et al., 2000; Van Schuylenbergh, Eynde & Hespel, 2004). An dieser Leistungsstruktur ist auch die Trainingsstruktur im Triathlon ausgerichtet. D.h. dass vorrangig Radfahren, Laufen und Schwimmen in unterschiedlichen Intensitätsbereichen als Trainingsmittel eingesetzt werden. Ein allgemeines Kraftausdauertraining ergänzt diese Trainingsformen (DTU, 2003).

Die  $VO_2\text{max}$  bietet sich zum einen wegen ihrer Leistungsrelevanz als Zielgröße für diese Arbeit an. Sie ist zudem ein Kriterium, das mit großer Genauigkeit bei einer Fahrrad Spiroergometrie bestimmt werden kann. Weiterhin ist von Abhängigkeiten im Wirkungsgefüge zwischen den einzelnen Trainingsinhalten auszugehen, die sich sowohl durch Teiltrainingseffekte als auch durch kumulative Trainingseffekte ergeben und die Entwicklung der maximalen Sauerstoffaufnahme beeinflussen (Hickson, Rosenkoetter & Brown, 1980; Hoffmann, 1993; Hohmann, 1994; Tanaka, 1994; Millet et al., 2002). Somit ist als Inputgröße auch die kardiopulmonale Beanspruchung der einzelnen Trainingsformen von hoher Relevanz, um schließlich den Zusammenhang zwischen Training und  $VO_2\text{max}$  aufklären zu können. Neben der trainingsinduzierten Beanspruchung werden weitere leistungsrelevante Belastungen und Erholungsmaßnahmen als Prädiktorvariable über eine psychologische Erholungs- und Beanspruchungs-Diagnostik erfasst.

Die vorliegende Arbeit ist durch eine explorative Vorgehensweise gekennzeichnet. Zunächst wird der Verlauf der Untersuchungsergebnisse deskriptiv dargestellt. Daran schließt sich eine Bewertung der Abbildungs- und Prognoseleistung des eigenen Modellansatzes im Vergleich zu den antagonistischen Trainings-Wirkungs-Modellen an. Durch den einzelfallbezogenen Forschungszugang ergibt sich eine beschränkte Stichprobengröße, sodass die Ergebnisse weitgehend qualitativ zur Präzisierung der theoretischen Vorannahmen diskutiert werden.



**Abbildung 4.1:** Studiendesign und Zeitplan der empirischen Einzelfallanalysen. (TD = Trainingsdaten; EBB = Erholung-Beanspruchungs-Bilanz; LF = Leistungs-fähigkeit)

Die empirischen Einzelfallanalysen wurden von Anfang September bis Anfang Dezember 2009 durchgeführt und fällt damit weitgehend mit der Übergangsperiode im Rahmentrainingsplan für die Sportart Triathlon zusammen (DTU, 2003). Der gesamte Untersuchungszeitraum der empirischen Einzelfallanalyse gliederte sich in drei Phasen (vgl. Abbildung 4.1). In der Baselinephase erfolgte mit drei Messwiederholungen eine Gewöhnung an die leistungsdiagnostische Untersuchung. In der darauf folgenden Trainingsphase wurden täglich beanspruchungsorientierte Trainingsdaten (TD) dokumentiert. Die allgemeine Erholungs-Beanspruchungs-Bilanz (EBB) und die Leistungs-fähigkeit (LF) wurden alle drei Tage an insgesamt 26 Messzeitpunkten erfasst. Die dritte Phase (Prognosephase) unterschied sich im methodischen Vorgehen nicht zur Trainingsphase. Die Differenzierung der Phasen ergibt sich lediglich daraus, dass die Daten der zweiwöchigen Prognosephase mit 4 Messzeitpunkten nicht für das Modelltraining verwendet wurden.

## 4.2 Probandenstichprobe

Die Versuchspersonen wurden für diese Studie über ein Rundschreiben an Sportvereine mit einer Triathlon-Abteilung im Großraum Stuttgart akquiriert. Die Einschlusskriterien für eine Studienteilnahme waren eine mehrjährige Trainingsgeschichte und ein Trainingsumfang von mindestens fünf Trainingseinheiten pro Woche. An der Untersuchung nahmen drei Triathleten teil. Zu Beginn der Untersuchung wurden alle Probanden schriftlich mit einer Studieninformation über die Ziele, den Ablauf, den Nutzen und mögliche Risiken der Untersuchung sowie über die Datenschutzbestimmungen informiert. Die Probanden erklärten sich schriftlich mit einer freiwilligen Teilnahme an der Studienteilnahme einverstanden (vgl. Anhang C). Um gesundheitliche Risiken ausschließen zu können, erfolgte bei

allen Probanden eine Belastungsuntersuchung durch einen niedergelassenen Kardiologen gemäß den Richtlinien der Deutschen Gesellschaft für Sportmedizin und Prävention (DGSP, 2002a). Die Studie wurde von der Ethik-Kommission der Medizinischen Fakultät der Universität Tübingen begutachtet und positiv bewertet. Die Tabelle 4.1 zeigt die anthropometrischen und leistungsdiagnostischen Daten der Versuchspersonen.

**Tabelle 4.1:** Anthropometrische und leistungsdiagnostische Daten der Versuchspersonen. Die Mittelwerte und Standardabweichungen beziehen sich auf den gesamten Untersuchungszeitraum. ( $\text{VO}_2\text{max}$  = maximale Sauerstoffaufnahme)

Proband	Geschlecht	Alter	Größe [cm]	Körpermasse [kg]	$\text{VO}_2\text{max}$ [ $\text{l}\cdot\text{min}^{-1}$ ]
P1	weiblich	21	180	$76,4 \pm 0,1$	$3,77 \pm 0,09$
P2	männlich	21	184	$68,2 \pm 0,6$	$3,55 \pm 0,13$
P3	männlich	39	170	$67,5 \pm 0,5$	$3,84 \pm 0,13$

## 4.3 Untersuchungsmethoden

### 4.3.1 Trainingsprotokollierung

Die Probanden führten ihr individuelles Training während des gesamten Untersuchungszeitraums ohne Vorgaben durch. Hierbei wurde die Dauer und die Trainingsherzfrequenz jeder Trainingseinheit erfasst. Die Messung erfolgte im Radfahren, Laufen und Krafttraining mit einer Kombination von Messgurt (Suunto Dual Comfort Belt, Suunto, Vantaa, Finnland) und Pulsuhr (Suunto t6c, Suunto, Vantaa, Finnland). Im Schwimmen wurden die Daten mit einem mess- und speicherfähigen Brustgurt (Suunto Memory Belt, Suunto, Vantaa, Finnland) aufgezeichnet. Beide Systeme messen die Herzfrequenz in einem 10-Sekunden-Intervall. Für die weitere Datenverarbeitung wurden die Daten mit einer Software (Suunto Training Manager Version 2.3.0, Suunto, Vantaa, Finnland) auf einen PC übertragen. Auch die Fahrrad-Ergospirometrie wurde jeweils als Trainingseinheit berücksichtigt. Hierbei wurde die Herzfrequenz mit einem EKG-Gerät ebenfalls in 10-Sekunden Intervallen aufgezeichnet (vgl. Kapitel 4.3.3).

Mit Gleichung 2.3 wurde dann die kardiopulmonale Beanspruchung als dimensionsloser Trainingsimpuls (TRIMP) in den Kategorien Rad, Laufen, Schwimmen und Kraft für jede Trainingseinheit berechnet. In die Faktoren  $X_i$  und  $k_i$  der Gleichung 2.3 geht bei der Berechnung zum einen die Ruheherzfrequenz ( $\text{HF}_{\text{basal}}$ ) ein. Daher wurde die  $\text{HF}_{\text{basal}}$  von allen Versuchspersonen täglich direkt nach dem Aufwachen palpatorisch über einen Zeitraum von 30 Sekunden bestimmt und über die Software bento für iPhone

(Filemaker GmbH, Unterschleißheim) auf einem iPod touch (Apple Inc., Cupertino, USA) protokolliert. Zum anderen ist bei beiden Faktoren die maximale Herzfrequenz zu berücksichtigen. Diese wurde aus der Herzfrequenzmessung während der Leistungsdiagnostik für die einzelnen Probanden abgeleitet (vgl. Kapitel 4.3.3). Abschließend wurde der TRIMP einzelner Trainingseinheiten jeweils zu dreitägigen Trainingsabschnitten in den vier Kategorien zusammengefasst. Für die Analyse und Prognose von Trainingswirkungen mit dem FF-Modell und dem PerPot-Modell wurden die Trainingsdaten einzelner Abschnitte anschließend noch zu einem „Gesamt-TRIMP“ aggregiert.

### 4.3.2 Psychologische Erholungs- und Beanspruchungsdiagnostik

Der Erholungs-Belastungs-Fragebogen für Sportler (EBF-Sport; Kellmann & Kallus, 2000) ist ein Verfahren, mit dem quantitativ und differenziert der aktuelle Erholungs-Beanspruchungs-Zustand diagnostizierbar ist. Der EBF-Sport umfasst 77 Items (vgl. Anhang A), mit denen systematisch und direkt die Häufigkeit subjektiv bewerteter Ereignisse, Zustände sowie Aktivitäten der letzten 3 Tage/Nächte abgefragt werden (vgl. Abbildung 4.2). Vier Items bilden jeweils einen von zwölf unspezifischen und sieben sportspezifischen Subtest. Die Subtest lassen sich darüber hinaus zu einem Globalindikator Gesamtbeanspruchungs- bzw. Gesamterholungswert weiter zusammen fassen.

***In den letzten 3 Tagen und Nächten***

... *fühlte ich mich körperlich fit*

0	1	2	3	<del>4</del>	5	6
<i>nie</i>	<i>selten</i>	<i>manchmal</i>	<i>mehrmals</i>	<i>oft</i>	<i>sehr oft</i>	<i>immerzu</i>

**Abbildung 4.2:** Beispielitem und Antwortmodus des EBF-Sport (Kellmann & Kallus, 2000).

Die internen Konsistenzen der einzelnen Subtests liegen zwischen  $\alpha = .67$  und  $\alpha = .89$  (Kellmann Kallus, 2000). Die Zuverlässigkeit bei Testwiederholungen mit dem EBF-Sport liegt für alle Subtests über  $r = 0.79$ . Damit sind reproduzierbare interindividuelle Unterschiede in der Erholungs- und Beanspruchungsbilanz zu erwarten. Die Retest-Reliabilität des Fragebogen nimmt mit zunehmendem zeitlichem Abstand ab. Dies zeigt, dass der EBF-Sport auf kurzfristige Befindensänderungen und Funktionsfluktuationen reagiert, weswegen er sich für Messwiederholungsdesigns eignet. Weitere Angaben zur Konstrukt- und Kriterienvalidität sind im Manual des EBF-Sport (ebd.) dokumentiert. Dort sind zudem Ergebnisse zur Reliabilität und Validität des EBF-Sport ausführlich anhand von Fallbeispielen beschrieben.

Der aktuelle Erholungs- und Beanspruchungs-Zustand der Probanden wurde alle drei Tage jeweils morgens am Tag der Leistungsdiagnostik mit dem EBF-Sport erhoben. Der Fragebogen war über die Software bento für iPhone (Filemaker GmbH, Unterschleißheim) auf einem iPod touch (Apple Inc., Cupertino, USA) abgebildet. Die Items wurden entsprechend zu den Subtests zusammengefasst und

daraus jeweils ein Globalindikator Gesamtbeanspruchungs- (GBW) bzw. Gesamterholungswert (GEW) bestimmt.

### 4.3.3 Leistungsdiagnostik

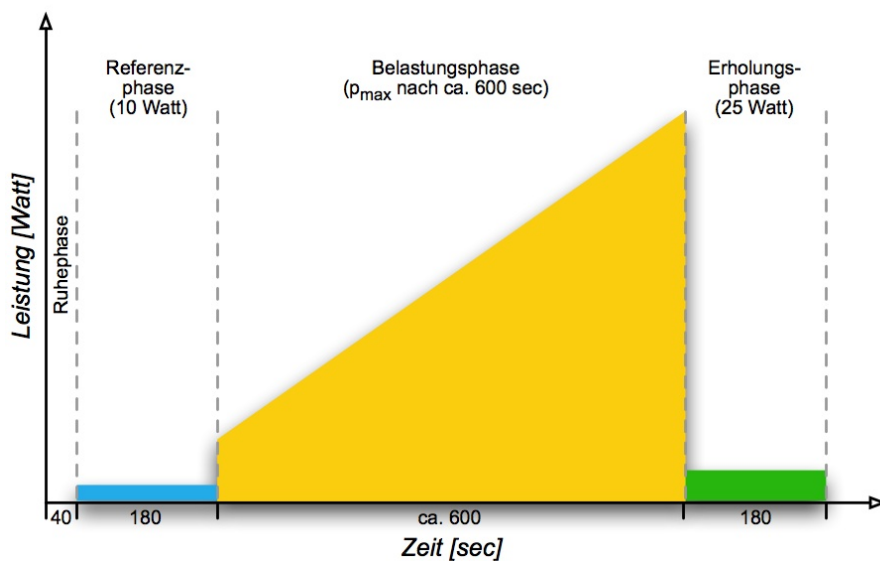
Die Versuchspersonen absolvierten alle drei Tage am Institut für Sport- und Bewegungswissenschaft der Universität Stuttgart eine Fahrrad Spiroergometrie mit Rampenprotokoll zur Bestimmung der maximalen Sauerstoffaufnahme. Der Test wurde immer zur gleichen Tageszeit auf einem Fahrradergometer (Excalibur Sport, Lode B.V., Groningen, Niederlande) in einem nicht-klimatisierten Raum durchgeführt. Das Ergometer wurde jeweils an die individuelle Sitzposition der Probanden angepasst. Alle Probanden trugen während der Messungen ihre eigenen Radschuhe. Die Schuhe waren für eine standardisierte Kraftübertragung auf die Kurbel fest über Klickpedale (Shimano, Osaka, Japan) mit dem Fahrradergometer verbunden.



**Abbildung 4.3:** Versuchsaufbau Spiroergometrie.

Die Versuchspersonen atmeten während des Tests Raumluft durch eine Silikonmaske (Oro-Nasal 7400 Vmask, Hans Rudolph, Inc., Shawnee, USA), die luftdicht über Mund und Nase angelegt war. An das offene System war ein Blendenspirozeptor zur Strömungsmessung (Messbereich 0 bis  $\pm 17$  l/sek.; Abweichung  $< \pm 2,5$  %) und eine Absaugstrecke angeschlossen. Die Volumen- und Gasanalyse erfolgte in einem PowerCube-Spiro (Ganshorn Medizin Electronic GmbH, Niederlauer) mit chemischer  $O_2$ -Zelle (Messbereich 0 - 100 %  $O_2$ ; Abweichung  $< \pm 0,1$  %) und Ultraschall- $CO_2$ -Analysator (Messbereich 0 - 100 %  $CO_2$ ; Abweichung  $< \pm 0,1$  %). Die ergometrischen und spirometrischen Daten wurden mit einem ERGOSPIRO-Messplatz MIKRO (Schiller Medizintechnik GmbH, Ottobrunn) auf einem PC

in 10-Sekunden-Intervallen aufgezeichnet und anschließend ausgewertet. Nach den Herstellerangaben wurde täglich der Gassensor mit Eichgas (15 % O<sub>2</sub>, 6,11 % CO<sub>2</sub>, 78,89 % N<sub>2</sub>) kalibriert. Vor jeder einzelnen Untersuchung wurde das Messsystem an die Umgebungsbedingungen (Raumtemperatur und Luftfeuchte) angepasst und eine Volumenkalibration mit einer Drei-Liter-Pumpe (Schiller, Medizintechnik GmbH, Ottobrunn) durchgeführt. Parallel zu den spiroergometrischen Messungen wurde die Herzfrequenz mit einem 12-Kanal EKG-Gerät (Cardiovit AT-104, Schiller Medizintechnik GmbH, Ottobrunn mit DT80 Sauganlage, Strässle & Co. Medizintechnik GmbH, Albstadt) kontrolliert und ebenfalls mit dem ERGOSIRO-Messplatz Mikro aufgezeichnet. Die Abbildung 4.3 zeigt den Versuchsaufbau.



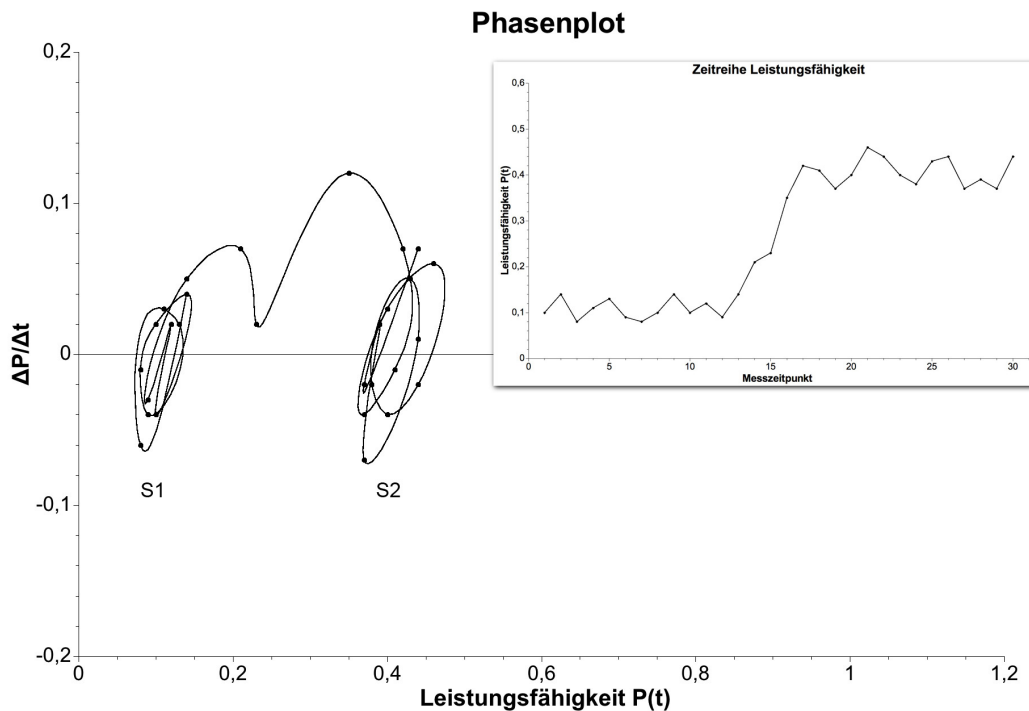
**Abbildung 4.4:** Belastungsprotokoll der Spiroergometrie (mod. nach Kroidl et al., 2007, S. 56).

Das Untersuchungsprotokoll der Spiroergometrie orientierte sich an den Leitlinien zur Belastungsuntersuchung (Ebene IV - 03/2002) in der Sportmedizin der DGSP (2002b). Das Belastungsprotokoll wurde als Rampenprofil bis zur maximalen Leistungsfähigkeit gefahren (Kroidl et al., 2007, S. 56). Zu Beginn der Untersuchung erfolgte eine 40-sekündige Ruhephase zur Synchronisation des Messsystems. Daran schloss sich eine 3-minütige Referenzphase mit 10 Watt Belastung an. In dieser Phase sollten die Probanden bereits eine Trittfrequenz von 70 - 90 min<sup>-1</sup> erreichen, die über die gesamte Untersuchung aufrecht zu erhalten war. Die Belastungsphase wurde mit einer kontinuierlichen Steigerung der Belastung gefahren. Die maximale Belastung ist bei einem Rampenprofil nach 8 - 12 Minuten zu erreichen. Die individuellen Belastungsparameter wurden während der Baselinephase ermittelt und anschließend über den gesamten Untersuchungszeitraum konstant gehalten. Die Abbruchkriterien für die Spiroergometrie waren ein Abfall der Trittfrequenz unter 60 min<sup>-1</sup> oder die subjektive empfundene Erschöpfung des Athleten. Die Untersuchung wurde nach einer 3-minütigen Erholungsphase mit 25 Watt Belastung beendet (vgl. Abbildung 4.4).



## 4.4 Methoden der Verlaufsanalyse

Für die statistische Auswertung der Untersuchungsergebnisse wurde weitgehend die Software SPSS 19 für Mac OS X (Armonk, New York, USA) eingesetzt. Die Abbildungen wurden mit der Software QtiPlot (Ion Vasilief) und Microsoft®Excel®2004 für Mac (Microsoft Corporation, Redmond, USA) erstellt. Für eine inspektive Trainings-/Leistungsverlaufsanalyse wurden alle Trainings-, Erholungs-, Beanspruchungs- und Leistungsdaten mit Histogrammen oder Polygonzügen dargestellt. Ergänzend wurden Mittelwerte, Standardabweichungen und lineare Trends in den Leistungsdaten berechnet.



**Abbildung 4.5:** Phasenplot einer fiktiven Zeitreihe. In der kleinen Abbildung ist eine fiktive Zeitreihe dargestellt. Die Veränderung der Leistungsfähigkeit  $\Delta P/\Delta t$  ist im Phasenplot gegenüber der Leistungsfähigkeit  $P(t)$  aufgetragen. Es lassen sich eindeutig zwei unterschiedliche Systemzustände S1 und S2 abgrenzen.

Zur Kontrolle des Prognosefehlers wurde unter systemdynamischer Perspektive die zeitliche Stabilität der Leistungsdaten überprüft (vgl. Kapitel 2.3.2). Hierfür wurde in einer graphischen Darstellung der Verlauf der interpolierten Leistungsfähigkeit  $\text{VO}_2\text{max}$  gegenüber ihrer zeitlichen Veränderung  $\frac{\Delta \text{VO}_2\text{max}}{\Delta t}$  in einem Phasenplot dargestellt (Edelmann-Nusser et al., 2009; Ganter, 2009; vgl. Abbildung 4.5). Sofern unterschiedliche Systemzustände vorherrschen, lassen sich diese durch Zonen stabiler Phasenverläufe und Übergangsbereiche qualitativ in der Darstellung abgrenzen.

## 4.5 Methoden der Analyse und Prognose von Trainingswirkungen

Das methodische Vorgehen der Analyse und Prognose von Trainingswirkungen mit künstlichen neuronalen Netzen wird im folgenden Kapitel näher beschrieben. Die Modellkalibrierung bzw. das Netztraining erfolgte jeweils mit den Daten der Trainingsphase. Auf dieser Grundlage wurde dann mit allen Modellen die Entwicklung der Leistungsfähigkeit über den Prognosezeitraum vorhergesagt (vgl. Abbildung 4.1).

Die Daten der Trainings-, Erholungs-/Beanspruchungs- und Leistungsdiagnostik wurden zur Trainingswirkungsanalyse für alle Modellansätze in gleicher Weise vorverarbeitet. Die Modellierung mit KNN setzt normalisierte Daten voraus. Daher wurden alle Werte linear auf den Wertebereich [0,1] transformiert (vgl. Kapitel 2.5.4). Obwohl in den Software- und Programm-Paketen der antagonistischen Modelle Normalisierungsroutinen integriert sind, hat die beschriebene Vorverarbeitung keinen Einfluss auf die Ergebnisse.

Nach der Analyse und Prognose von Trainingswirkungen wurden die Daten entsprechend wieder retransformiert, damit die Güte der Modellanpassung und der Prognose bestimmt werden kann. Für alle Verfahren der Trainingswirkungsanalyse wurde die Modell- und Prognosegüte mit den Fehlermaßen RMS und RMSE sowie der Determinationskoeffizienten als Zusammenhangsmaß für die Trainingsphase berechnet (vgl. Kapitel 2.3.2). Die Berechnung erfolgte mit der Software Microsoft®Excel®2004 für Mac (Microsoft Corporation, Redmond, USA) und SPSS 19 für Mac OS X (Armonk, New York, USA).

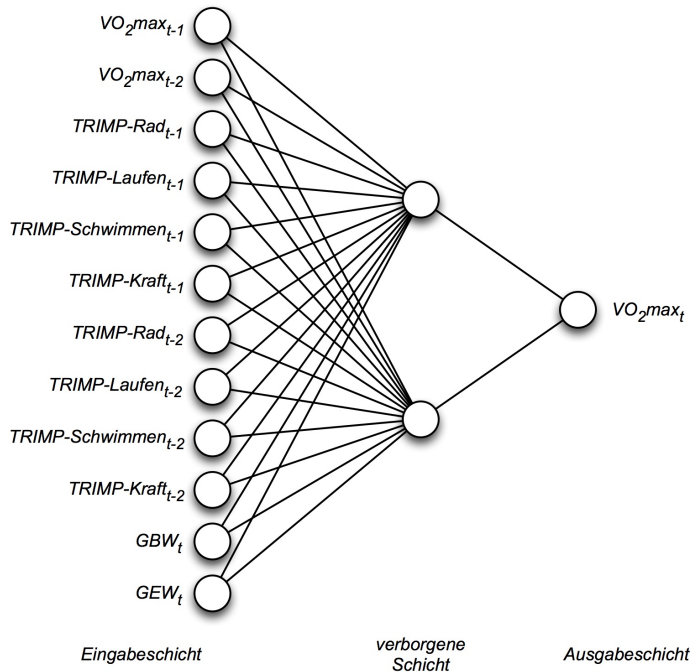
### 4.5.1 Multivariate Zeitreihenanalyse mit künstlichen neuronalen Netzen

Die Modellierung mit KNN wurde softwareseitig mit dem Stuttgarter Neuronale Netze Simulator (SNNS) umgesetzt (Zell et al., 2000). Hierfür stand eine Java Umgebung „Java Neural Network Simulator 1.1“ mit grafischer Benutzeroberfläche zur Verfügung, die auf der Version 4.2 des SNNS aufgebaut ist. Das Programm stellt viele Möglichkeiten zum Aufbau, zum Netztraining und zur Veranschaulichung von KNN zur Verfügung.

Für die Analyse und Prognose von Trainingswirkungen mit KNN (KNN-Modell) wurde im ersten Schritt die grundlegende Struktur des Analyse- und Prognosemodells definiert. Neben inhaltlichen Kriterien haben methodische Restriktionen die Entwicklung der Netzwerkstruktur beeinflusst. Da maximal 26 Datensätze für das Netztraining zur Verfügung standen, musste darauf geachtet werden, die Komplexität der KNN gering zu halten.

Für das Prognosemodell wurde ein MLP mit drei Schichten eingesetzt (vgl. Abbildung 4.6). Das Neuron der Ausgabeschicht repräsentierte die Leistungsfähigkeit  $VO_{2max_t}$ . Die verdeckte Schicht bestand aus zwei Neuronen. Die zeitliche Dynamik des Trainingsprozesses wurde durch den Zusammenhang

zwischen der Leistungsfähigkeit  $VO_2max_t$  und dem Leistungsverlauf abgebildet. Dazu wurde die Leistungsfähigkeit von zwei zurückliegenden Messzeitpunkten  $VO_2max_{t-1}$  und  $VO_2max_{t-2}$  in das Modell einbezogen, um Trends im Signalverlauf berücksichtigen zu können.



**Abbildung 4.6:** Struktur des künstlichen neuronalen Netzes mit drei Schichten zur Analyse und Prognose von Trainingswirkungen.

Als exogene Prädiktorvariablen wurde zum einen der TRIMP in den vier Kategorien Rad (TRIMP-Rad<sub>t</sub>), Laufen (TRIMP-Laufen<sub>t</sub>), Schwimmen (TRIMP-Schwimmen<sub>t</sub>) und Kraft (TRIMP-Kraft<sub>t</sub>) berücksichtigt. Da bisher kaum gesicherte Erkenntnisse zur zeitlichen Struktur von Trainingseffekten im Ausdauertraining vorliegen, ist es auch nur eingeschränkt möglich, die zeitliche Tiefe eines relevanten Zeitfensters für den Trainingsinput zu bestimmen (Hickson, Hagberg, Ehsani & Holloszy, 1981). Somit wurden aus pragmatischen Gründen zwei Trainingsabschnitte als leistungsbeeinflussend angenommen, um die Anzahl der Inputneuronen zu begrenzen. Zum anderen wurde die befindensorientierte Bewertung des Erholungs-Beanspruchungs-Zustands über die Globalindikatoren Gesamtbeanspruchungswert (GBW<sub>t</sub>) und Gesamterholungswert (GEW<sub>t</sub>) als weitere unabhängige Variablen in die Eingabeschicht integriert. Wegen des Messanspruchs des EBF-Sport, die aktuelle Erholungs-Beanspruchungs-Bilanz abzubilden und wegen der abnehmenden Wiederholungszuverlässigkeit wurde der Einfluss der EBF-Sport Globalindikatoren zum jeweiligen Messzeitpunkt auf die Leistungsfähigkeit abgebildet.

Da sich im wesentlichen das Backpropagation mit Momentum und das RPROP als Trainingsalgorithmen für die Zeitreihenanalyse etabliert haben, wurden beide Verfahren eingesetzt und verglichen. Die weiteren Parameter der Trainingsalgorithmen sowie die weiteren Merkmale der Netzwerktopologie werden im Überblick in Tabelle 4.2 dargestellt. Die Auswahl der Modellparameter orientierte sich dabei im Wesentlichen an der umfangreichen Literaturanalyse von Zhang et al. (1998) und dem bereits beschriebenen Vorgehen von Sharda und Patil (1992). Daraus ergaben sich neun unterschiedliche

Kombinationen von Parametern für das Training mit dem RPROP-Algorithmus und ein Parametersatz für das Training mit dem BPM-Verfahren, auf deren Basis für jeden Proband die Analyse und Prognose von Trainingswirkungen erfolgte.

**Tabelle 4.2:** Merkmale der Netzwerktopologie und der Trainingsparameter zur Analyse und Prognose von Trainingswirkungen mit künstlichen neuronalen Netzen.

Parameter / Merkmal	Backpropagation mit Momentum	RPROP
Aktivierungsfunktion verborgene Schicht	tanh	tanh
Aktivierungsfunktion Ausgangsschicht	logistisch	logistisch
Initialisierung des Netzes	zufällig [-1,1]	zufällig [-1,1]
Anzahl der Trainingsschritte	10.000	10.000
Präsentation der Muster	zufällig	zufällig
Lernparameter $\eta$	0,1; 0,5; 0,9 jeweils in Kombination mit einem Momentum-Parameter	
Momentum-Parameter $\mu$	0,1; 0,5; 0,9 jeweils in Kombination mit einem Lernparameter	
$\Delta_{min}$		0,1
$\Delta_{max}$		30

Die KNN wurden mit den dargestellten Eingabemustern und der entsprechenden Netzausgabe trainiert (vgl. Abbildung 4.6). Da der Leistungsverlauf in der Modellstruktur berücksichtigt wurde, reduzierte sich die Anzahl auf 24 Wertepaare aus der Trainingsphase. Zur weiteren Berechnung der Modellgüte wurden dem trainierten Netz alle 24 Eingabemuster der Trainingsphase präsentiert und die Ausgabe dokumentiert.

Im Anschluss an das Modelltraining erfolgte die Prognose der Leistungswerte über die vier Messzeitpunkte der Prognosephase. Hierfür wurden jeweils die einzelnen Datenmuster den KNN präsentiert und die Leistungsfähigkeit berechnet. Die prognostizierten Leistungswerte wurden iterativ für die folgenden Prognosezeitpunkte übernommen. Die Datenmuster setzten sich weiterhin aus dem gegebenen Trainingsinput und den Globalindikatoren der Erholungs-Beanspruchungs-Diagnostik zusammen. Für jeden Probanden wurde aus den Analysen mit den unterschiedlichen Modellparametern diejenige op-

timale Konfiguration ausgewählt, die zur geringsten Abweichung sowohl bei der Modellanpassung als auch bei der Prognose führt.

Darüber hinaus wurden die Effekte der Komplexitätszunahme bestimmt. Mit den optimalen Modellkonfigurationen wurden für jeden Probanden zusätzlich Analysen und Prognosen der Trainingswirkungen auf der Basis von reduzierten Eingabedaten berechnet. Hierfür wurden in einem ersten Schritt die Trainingsinhalte zu einem „Gesamt-TRIMP“ zusammen gefasst (Modell A; vgl. Abbildung 4.7). In einem weiteren Schritt wurde der Modellinput auf den „Gesamt-TRIMP“ beschränkt (Modell B). Die autoregressive Komponente wurde jeweils beibehalten, um weiterhin die zeitliche Abhängigkeit in der Modellstruktur berücksichtigen zu können.




Abbildung 4.7: Netzwerktopologie bei reduzierter Modellkomplexität.

Aufgrund der geringen Anzahl der einzelnen Datenmuster wurde der gesamte Datensatz für die Validierung der neuronalen Netze nicht in einen Trainings- und einen Testdatensatz aufgeteilt. Damit eine möglichst große Datenmenge für das Netztraining zur Verfügung stand, erfolgte die Validierung anhand der Prognoseleistung. Damit standen ca. 15 % der gesamten Datenmenge als Testdaten zur Verfügung, die für das Netztraining nicht präsentiert wurden und somit unbekannt waren.

#### 4.5.2 Fitness-Fatigue-Modell

Die Leistungsfähigkeit  $p_t$  ( $VO_2max$ ) an jedem dritten Tag  $t$  wurde mit folgender Modellgleichung berechnet (vgl. Kapitel 2.4.1.1 und Gleichung 2.13):

$$p_t = p_0 + k_1 \sum_{i=1}^{t-1} w_i e^{-\frac{t-i}{\tau_1}} - k_2 \sum_{i=1}^{t-1} w_i e^{-\frac{t-i}{\tau_2}} \quad (4.1)$$

$p_0$  ist die  $VO_2max$  zum ersten Messzeitpunkt. Der Trainingsinput  $w_i$  ergibt sich aus dem „Gesamt-TRIMP“ einzelner Trainingsabschnitte.

Die Kalibrierung des Modells mit den Datensätzen der Trainingsphase und die Prognose der letzten vier Leistungswerte erfolgte mit einem Programm-Paket für MATLAB (Mathworks<sup>®</sup>, Natick, USA),

das von Ganter (2009) entwickelt und beschrieben wurde. Die individuellen Modellparameter werden dabei mit Hilfe eines „least-square-Algorithmus“ bestimmt. In das Programm-Paket ist hierfür die MATLAB Optimization Toolbox eingebunden. Wegen der bereits diskutierten Probleme mit zeitvarianten Modellparametern wurden konstante Parameter für die Modellkalibrierung eingesetzt. Die Startwerte und Wertebereiche der Modellparameter orientierten sich an den Empfehlungen von Banister (1991) sowie Busso et al. (1997) (vgl. Tabelle 4.3). Nach der individuellen Modellkalibrierung wurde die Leistungsentwicklung über die Prognosephase anhand des Trainingsinputs berechnet.

**Tabelle 4.3:** Startwerte und Wertebereich der Modellparameter des FF-Modells (Banister, 1991; Busso et al. 1997; Ganter, 2009).

Parameter	Startwert	Wertebereich
Zeitkonstante $\tau_1$ der Fitness-Komponente	$\tau_1 = 45$ Tage	$30 < \tau_1 < 60$ Tage
Zeitkonstante $\tau_2$ der Fatigue-Komponente	$\tau_2 = 15$ Tage	$1 < \tau_2 < 20$ Tage
Konstante $k_1$ der Fitness-Komponente	$k_1 = 1$	
Konstante $k_2$ der Fatigue-Komponente	$k_2 = 2$	

#### 4.5.3 Performance Potential Modell

Für die Analyse und Prognose von Trainingswirkungen mit dem PerPot-Modell wurde das Softwarepaket PerPot Simulationsumgebung Version 10-4 (Universität Mainz) eingesetzt. Das Modell arbeitet mit einer äquidistanten Zeitskala. Diese Anforderung war durch das Studiendesign mit einem Messintervall von 3 Tagen erfüllt. Das PerPot-Modell kann ebenfalls nur eine Variable als Modellinput verarbeiten. Daher wurde der Trainingsinput analog zur Modellierung mit dem FF-Modell als „Gesamt-TRIMP“ einzelner Trainingsabschnitte berücksichtigt.

Im ersten Schritt wurden die Input- und Output-Daten im „Calibration-Modul“ der PerPot Simulationsumgebung auf den Wertebereich  $[0,1]$  normiert. Durch die eingangs beschriebene Vorverarbeitung der Daten ergaben sich aber keine weiteren relevanten Veränderungen der Daten. In einem zweiten Arbeitsschritt des „Calibration-Moduls“ wurden die Modellparameter ( $DR$ ,  $DS$ ,  $DSO$ ) und die Startwerte der einzelnen Potentiale ( $RP_0$ ,  $SP_0$ ,  $PP_0$ ) mit einem genetischen Algorithmus für eine Anpassung der modellierten an die realen Leistungswerte bestimmt. Diese Modellkallibrierung erfolgte ebenfalls mit den 26 Datensätzen der Trainingsphase.

Mit Hilfe des „Prediction-Moduls“ der Simulationsumgebung wurde im Anschluss an die Kalibrierung die Entwicklung des Leistungsverlaufs über den Prognosezeitraum bestimmt. Hierfür berechnet das Modul die einzelnen Leistungswerte auf der Grundlage des kalibrierten Modells und des vorgegebenen Trainingsinputs.

## **4.6 Methodendiskussion**

### **4.6.1 Studiendesign, Forschungszugang und Probandenstichprobe**

Diese Untersuchung orientiert sich im Allgemeinen an der Vorgehensweise, die Schlicht (1988; 1990) als Forschungsstrategie für intensive Ansätze im (Leistungs-) Sport vorschlägt. Mit der vorliegenden Arbeit wird der zweite Arbeitsschritt dieses Schemas erreicht. Vor allem aus forschungsökonomischen Gründen konnte die Zahl der Versuchspersonen nicht gesteigert werden. Dennoch ist davon auszugehen, dass begründete Handlungsempfehlung abgeleitet werden können. Diese bleiben aber auf grundlegende Aussagen zur Anwendbarkeit des Verfahrens begrenzt. Die hohe Spezifik simulativer Trainingswirkungsmodelle und die Begrenzung auf eine Sportart limitieren zudem die Interpretationsmöglichkeiten.

Für die spezielle Fragestellung der Prognose von Trainingswirkungen orientiert sich das Vorgehen am Ablaufschema, das in Kapitel 2.3.2 vorgestellt wurde. Durch die Struktur der Arbeit und das Studiendesign werden die ersten acht Arbeitsschritte umgesetzt.

Der Forschungszugang über den Trainingsprozess in der Sportart Triathlon ist für eine simulative Trainingswirkungsanalyse besonders geeignet. In anderen Untersuchungen wurden bislang häufig Sportarten mit einfacher Leistungsstruktur und enger Input-Output-Relation betrachtet. Im Vergleich dazu ergibt sich aus der Leistungsstruktur im Triathlon einerseits ein gesteigerter Anspruch an die Komplexität, die mit einem Trainings-Wirkungs-Modell abzubilden ist. Andererseits ist mit der maximalen Sauerstoffaufnahme immer noch ein eindeutig leistungsrelevantes Kriterium vorhanden, das von spezifischen Teiltrainingseffekten sowie kumulativen Trainingseffekten abhängig ist.

Durch den Zeitpunkt des Untersuchungszeitraums ist keine große Dynamik der Leistungsentwicklung zu erwarten. Mit einer deutlichen Belastungsreduktion wird in dieser Phase sogar bewusst ein zeitweiliger Verlust der sportlichen Form in Kauf genommen. Damit wird in der Übergangsperiode ein psychophysischer Zustand erreicht, der in den folgenden Abschnitten wieder höhere Belastungen zulässt (Schnabel et al., 2005, S. 385 - 390). Die Untersuchung wäre aber in keiner anderen Phase im Trainingsjahr möglich, da sonst Trainingslager, Wettkämpfe oder Urlaubsreisen eine regelmäßige Diagnostik der Ausdauerleistungsfähigkeit nicht ermöglichen.

### **4.6.2 Verfahren der empirische Einzelfallanalysen**

Für eine beanspruchungsorientierte Trainingsdiagnostik ist bisher nur das Verfahren von Banister et al. (1986) bekannt, das gleichzeitig gewichtete Intensitäts- und Zeitparameter berücksichtigt. Bei der Bestimmung des Trainingsimpulses sind nur geringe Messungenauigkeiten zu erwarten. Der Einsatz präziser Herzfrequenzmesser ermöglicht eine genaue Datenerfassung. Bei der palpatorischen Ruheherzfrequenzmessung über 30 Sekunden ergeben sich ebenfalls keine relevanten Abweichungen. Unspezifisch hingegen ist die Berechnung des TRIMP mit der maximalen Herzfrequenz, die bei der

Radergometrie bestimmt wurde. Im günstigsten Fall wird für jede Trainingsform ein eigenständiges Herzfrequenzmaximum ermittelt, da disziplinspezifische Unterschiede feststellbar sind (Dal Monte, 1974 zit. nach Hollmann & Strüder, 2009). Bei Einzelmessungen der maximalen Herzfrequenz sind sicherlich auch methodische Schwierigkeiten zu erwarten, weshalb der Maximalwert aus den 33 spiroergometrischen Untersuchungen als gute Schätzung angenommen werden kann.

Meeusen et al. (2006) weisen auf grundlegende Probleme einer psychologischen Befindlichkeitsdiagnostik hin. Zum einen kann nicht kontrolliert werden, ob wahrheitsgemäße Angaben gemacht werden. Es ist aber davon auszugehen, dass diese Problematik keine Relevanz hat. Die Versuchspersonen waren sich der Bedeutung wahrheitsgetreuer Angaben für den Erfolg dieser Untersuchung bewusst und hatten keine Konsequenzen zu erwarten. Zum anderen ist auch von einer tageszeitlichen Abhängigkeit der Ergebnisse von Befragungen auszugehen. Dies wurde dadurch kontrolliert, dass der Fragebogen immer morgens zu beantworten war.

Gegenüber den Verfahren zur Trainings- sowie zur Erholungs- und Beanspruchungsdiagnostik ist die Diagnostik der Ausdauerleistungsfähigkeit kritischer zu betrachten. Hierbei sind besonders hohe Anforderungen an die Reliabilität der Einzelmessungen zu stellen. Daher wurde im Rahmen dieser Arbeit vor allem aus methodischen Gründen die maximale Sauerstoffaufnahme als Maß für die Ausdauerleistungsfähigkeit bestimmt. Wenngleich submaximale Leistungsparameter bessere Prädiktoren der komplexen Wettkampfleistung im Triathlon sind (Sleivert et al., 1996; Schabort et al., 2000; Van Schuylenbergh et al., 2004), sprechen Schwierigkeiten bei der Ermittlung dieser Parameter gegen deren Verwendung (Meyer, Lucia, Earnest & Kindermann, 2005). Für spiroergometrische Untersuchungen sind bisher keine objektiven Auswertelgorithmen vorhanden. Leistungsschwellen werden anhand einer graphischen Auswertung der Untersuchungsergebnisse bestimmt. Die Objektivität der  $VO_2\text{max}$ -Bestimmung ist hingegen sehr hoch, da lediglich der Maximalwert zu bestimmen ist.

Der Zusammenhang zwischen der Wettkampfleistung im Triathlon und der maximalen Sauerstoffaufnahme ist nicht von der Testform abhängig. Sowohl bei der Laufband- als auch bei der Fahrrad-Spiroergometrie werden vergleichbare Ergebnisse erzielt (Schabort et al., 2000). Die Fahrrad-Spiroergometrie bietet sich aber vor allem aus untersuchungsmethodischen Gründen an. Durch die sitzende Position während des gesamten Tests sind keine Messfehler durch Bewegungen der Silikonmaske zu erwarten. Zudem erfordert eine Laufbandergometrie eine längere Gewöhnung an das Testsetup und ist mit deutlich höheren Sicherheitsanforderungen verbunden.

In Abhängigkeit einer entsprechenden Geräteeichung, vergleichbaren Umgebungsbedingungen und standardisierten Versuchsdurchführung ist die Reliabilität einer Messung der maximalen Sauerstoffaufnahme sehr hoch ( $r > 0.95$ ) (Bruce, Kusumi & Hosmer, 1973). Standardisierte Versuchsbedingungen wurden dadurch geschaffen, dass die Messungen jeweils zur gleichen Tageszeit, bei gleicher Sitzstellung des Rads und mit den gleichen Schuhen durchgeführt wurden. Schwierigkeiten ergaben sich bei der Passung der Silikonmasken. Daher konnte über den gesamten Untersuchungszeitraum nicht die gleiche Maskengröße verwendet werden. Um Undichtigkeiten und Messfehler auf jeden Fall aus-



schließen zu können, wurde der Sitz der Maske mehrfach kontrolliert und gegebenenfalls eine Maske anderer Größe eingesetzt. Zudem erfolgte mit den Messungen der Baselinephase eine Gewöhnung an das Messinstrumentarium und den Untersuchungsablauf.

Das Messinstrumentarium wurde immer entsprechend den Herstellerangaben kalibriert. Die Umgebungsbedingungen wurden als Korrekturgröße vor jeder Untersuchung bestimmt und über die Messsoftware eingegeben. Da die Temperatur und die Luftfeuchtigkeit im Untersuchungsraum aber nicht regelbar waren, muss ein Einfluss der beiden Faktoren auf die Untersuchungsergebnisse kritisch geprüft werden. Die Raumtemperatur schwankte zwischen 21,7 und 27,7 °C. Ein systematischer Zusammenhang zwischen der Raumtemperatur und der Leistungsfähigkeit konnte jedoch nicht festgestellt werden. Während bei Proband P3 ein mittlerer umgekehrt proportionaler Zusammenhang zwischen den beiden Größen besteht ( $r = -0,63$ ), ist bei P1 kein Zusammenhang ( $r = 0,10$ ) und bei Proband P2 ein positiver Zusammenhang ( $r = 0,47$ ) feststellbar. Daher ist von keinem Einfluss der Raumtemperatur auf die  $VO_2\text{max}$  auszugehen, was von Sawka & Young (2000) für mittlere Temperaturen bestätigt wird.

Die Auswirkungen der Luftfeuchtigkeit auf die maximale Sauerstoffaufnahme ist bisher nicht systematisch untersucht. Ein mittlerer Zusammenhang mit der Leistungsfähigkeit zeigt sich aber bei den Probanden P1 und P2 ( $r = 0,39$  bzw.  $0,42$ ). Bei Proband P3 konnte diese Beziehung nicht festgestellt werden ( $r = 0,10$ ). Da die Werte der Luftfeuchtigkeit (18 - 51 %) einerseits weitgehend im Rahmen der Vorgaben für spiroergometrische Untersuchungen liegen und zudem der Zusammenhang nicht bei allen Probanden erkennbar ist, ist ebenfalls kein Einfluss auf die  $VO_2\text{max}$  anzunehmen. Es spricht vielmehr dafür, dass ein zufälliger Zusammenhang besteht. In der zweiten Hälfte des Untersuchungszeitraums wurde jahreszeitlich bedingt das Ergometrielabor beheizt, was zu einer Abnahme der Luftfeuchtigkeit führt. Dieser Rückgang fällt mit der Abnahme der Leistungsfähigkeit bei P1 und P2 in der Übergangsperiode zusammen.

Die Messgeräteabweichung der Gasanalyse mit dem PowerCube-Spiro ist mit einem Wert  $< \pm 0,1 \%$  zu vernachlässigen. Etwas höher ist die Messungenauigkeit der Volumenbestimmung ( $< \pm 2,5 \%$ ). Da im Rahmen dieses einzelfallorientierten Untersuchungsansatzes keine inferenzstatistischen Verfahren zum Einsatz kommen, müssen die zufälligen Messabweichungen nicht gesondert berücksichtigt werden. Zudem bleibt die mögliche Gesamtabweichung der Gas- und Volumenanalyse im Verhältnis zur durchschnittlichen Gesamtvariation der Messwerte von 14 % in einem akzeptablen Bereich.

### 4.6.3 Methoden der Analyse und Prognose von Trainingswirkungen

Eine ausführliche methodische Diskussion der antagonistischen Trainings-Wirkungs-Modelle erfolgte bereits in den Kapiteln 2.4.1.1, 2.4.1.2 und 2.4.4. Hellard et al. (2006) betonen, dass KNN grundsätzlich eine geeignete Methode zur Analyse und Prognose von Trainingswirkungen sind, vorausgesetzt das vorrangige Ziel ist ausschließlich die Vorhersage von Leistungsergebnissen. Das „Black-Box“-Verhalten neuronaler Netze eignet sich nicht, um mögliche kausale Zusammenhänge aufklären zu können.

Feed-Forward-Netze lernen, bestimmten Mustern von Eingabedaten eine bestimmte Ausgabe zuzuordnen. D.h. bei einer Trainingswirkungsanalyse mit KNN werden Muster von Inputdaten einem Leistungswert zugeordnet. Dies schränkt die Anwendungsmöglichkeit künstlicher neuronaler Netze für die Analyse und Prognose von Trainingswirkungen insofern zusätzlich ein, da vor allem die Prognoseleistung von der Anzahl, der Struktur und der Qualität der Eingabedaten abhängig ist. Im konkreten Anwendungsfall bedeutet dies, dass Eingabedaten aus zeitlich begrenzten und spezifischen (Trainings-) Perioden nur eine eingeschränkt generalisierte Abbildung der Zusammenhänge ermöglichen. Unberührt davon bleibt die Problematik einer mangelnden zeitlichen Stabilität.

Die Fähigkeit zur Generalisierung ließe sich einerseits durch eine Verlängerung der Trainingsphase und umfangreichere Datensätze verbessern. Dies ist aber aus forschungsökonomischen Gründen kaum möglich. Andererseits könnten durch eine Differenzenbildung Trend- und Saisonkomponenten im Verlauf der Zeitreihe beseitigt werden. Damit wird dann nicht mehr der Zusammenhang zwischen absoluten Leistungswerten, sondern der Zusammenhang zur Leistungsveränderung abgebildet. Im Rahmen dieser Arbeit wird die Analyse- und Prognoseleistung aber im Vergleich zu den bereits vorhandenen antagonistischen Modellen bewertet. Da diese Verfahren aber die tatsächlichen Leistungswerte verarbeiten, wird zur besseren Vergleichbarkeit auf eine Trendbereinigung verzichtet.

Darüber hinaus ist bezüglich des Modellansatzes kritisch zu bewerten, dass die Tiefe der Zeitfenster von Trainings- und Leistungsdaten vorrangig aus pragmatischen Gründen begrenzt wurden. Da hierzu bisher kaum gesicherte Erkenntnisse vorliegen, muss dies in der Folge als isolierte Fragestellung weiter betrachtet werden (vgl. auch Kapitel 7). In enger Verknüpfung zur Netzwerktopologie steht auch die Anzahl der Trainingsdatensätze. Bei 26 Verknüpfungen des neuronalen Netzes sollten 52 Datensätze vorhanden sein. Mit maximal 26 Trainingsdatensätzen wird die Richtlinie deutlich unterschritten, was sich auf die Abbildungsleistung negativ auswirken kann.

**Tabelle 4.4:** Validierung der künstlichen neuronalen Netze zur Analyse und Prognose von Trainingswirkungen. Dargestellt sind die Ergebnisse der Modellanpassung und der Prognoseleistung mit den optimalen Modellparametern. (MSE = mean square error; RMSE = root mean square error;  $r^2$  = Determinationskoeffizient)

Proband	Modellanpassung			Prognoseleistung	
	MSE	RMSE	$r^2$	MSE	RMSE
P1	0,00	0,03	0,91	0,00	0,06
P2	0,00	0,05	0,94	0,02	0,12
P3	0,00	0,06	0,84	0,00	0,06
<b>Mittelwerte</b>	0,00	0,05	0,89	0,01	0,08

Problematisch ist auch die Datenbasis für eine Prognose der Leistungsentwicklung zu betrachten. Die Trainingsdaten ergeben sich aus der konkreten Trainingsplanung und die Leistungswerte werden schrittweise bei der Prognose übernommen. Für zukünftige Trainingsabschnitte liegen die Werte der

Erholungs- und Beanspruchungsdiagnostik aber normalerweise nicht vor. In dieser Studie konnten die realen Werte in die Leistungsvorhersage einbezogen werden. Im Anwendungsfall muss der Erholungs- und Beanspruchungszustand des einzelnen Athleten dann abgeschätzt werden.

Die Netzvalidierung erfolgte anhand der Prognoseleistung über die vier Messzeitpunkte der Prognosephase. In Tabelle 4.4 sind die Ergebnisse der optimalen Modellanpassung und Prognoseleistung für alle Versuchspersonen zusammen gefasst (vgl. Kapitel 5.2.1). Der RMSE der Prognosephase beträgt im Mittel für alle Probanden  $0,08 \text{ l}\cdot\text{min}^{-1}$ . Setzt man den RMSE jeweils in Bezug zur durchschnittlichen  $\text{VO}_2\text{max}$ , ergibt sich daraus eine mittlere Abweichung von 2,2 %. Damit wird ein akzeptables Maß für die Genauigkeit der Abbildung unbekannter Datenmuster durch das neuronale Netz erreicht. Veränderungen der Netzstruktur oder der Modellparameter sind demnach nicht vorzunehmen. Aufgrund der geringen Abweichungen ist ebenso davon auszugehen, dass die Anzahl der Trainingsdatensätze ausreichend ist.

# Kapitel 5

## Ergebnisse

### 5.1 Inspektive Verlaufsanalyse der Untersuchungsergebnisse

Aus den empirischen Einzelfallanalysen ergeben sich die Mittelwerte und Standardabweichungen der Trainings-, der Erholungs-Beanspruchungs- sowie der Leistungsdaten, die in Tabelle 5.1 dargestellt werden. Die Mittelwerte der Trainingsdaten beziehen sich jeweils auf den TRIMP der dreitägigen Trainingsabschnitte. Proband P3 hat während des Untersuchungszeitraums das umfangreichste Training absolviert. Während die Probanden P1 und P2 den Trainingsschwerpunkt vor allem auf das Schwimm- und Lauftraining gelegt haben, hat Proband P1 das Radtraining mit hohem Umfang absolviert.

**Tabelle 5.1:** Mittelwerte und Standardabweichungen der Trainings-, Erholungs-Beanspruchungs- und Leistungsdaten in Bezug zum gesamten Untersuchungszeitraum. (TRIMP = Trainingsimpuls; GBW = Gesamtbelastungswert; GEW = Gesamterholungswert; VO<sub>2</sub>max = maximale Sauerstoffaufnahme)


Proband	TRIMP				GBW	GEW	VO <sub>2</sub> max [l·min <sup>-1</sup> ]
	Rad	Laufen	Schwimmen	Kraft			
P1	65 ± 61	112 ± 112	112 ± 119	5 ± 15	1,6 ± 0,3	3,1 ± 0,6	3,77 ± 0,09
P2	26 ± 37	118 ± 78	30 ± 41	7 ± 11	1,9 ± 0,4	3,9 ± 0,6	3,55 ± 0,13
P3	228 ± 188	90 ± 84	41 ± 63	16 ± 21	2,4 ± 0,3	2,5 ± 0,4	3,84 ± 0,13

Alle Probanden zeigen einen höheren Gesamterholungs- als Gesamtbelastungswert. Der Unterschied ist besonders bei den Probanden P1 und P2 deutlich. Die hohen Standardabweichungen deuten auch auf große Schwankungen des GEW hin. Die Ergebnisse des EBF-Sport können nicht als Absolutwerte interindividuell bewertet werden, sondern sind nur im intraindividuellen Zeitprofil zu betrachten (Kellmann & Kallus, 2000; vgl. Kapitel 5.1.2). Bei den Probanden P1 und P3 wurde im Mittelwert

über den gesamten Untersuchungszeitraum ähnlich hohe Werte der maximalen Sauerstoffaufnahme von  $3,77 \text{ l}\cdot\text{min}^{-1}$  bzw.  $3,84 \text{ l}\cdot\text{min}^{-1}$  gemessen. Die absolute  $\text{VO}_2\text{max}$  von P2 ist mit  $3,55 \text{ l}\cdot\text{min}^{-1}$  etwas geringer, bezogen auf das Körpergewicht hat Proband P2 aber die zweithöchste relative Sauerstoffaufnahme  $52,1 \text{ ml}\cdot\text{min}^{-1}\cdot\text{kg}^{-1}$ . Bei P3 wurde mit  $56,9 \text{ ml}\cdot\text{min}^{-1}\cdot\text{kg}^{-1}$  die höchste und bei P1 mit  $49,3 \text{ ml}\cdot\text{min}^{-1}\cdot\text{kg}^{-1}$  die niedrigste Leistungsfähigkeit gemessen. Die einzelnen Untersuchungsergebnisse werden in den folgenden Abschnitten näher betrachtet.

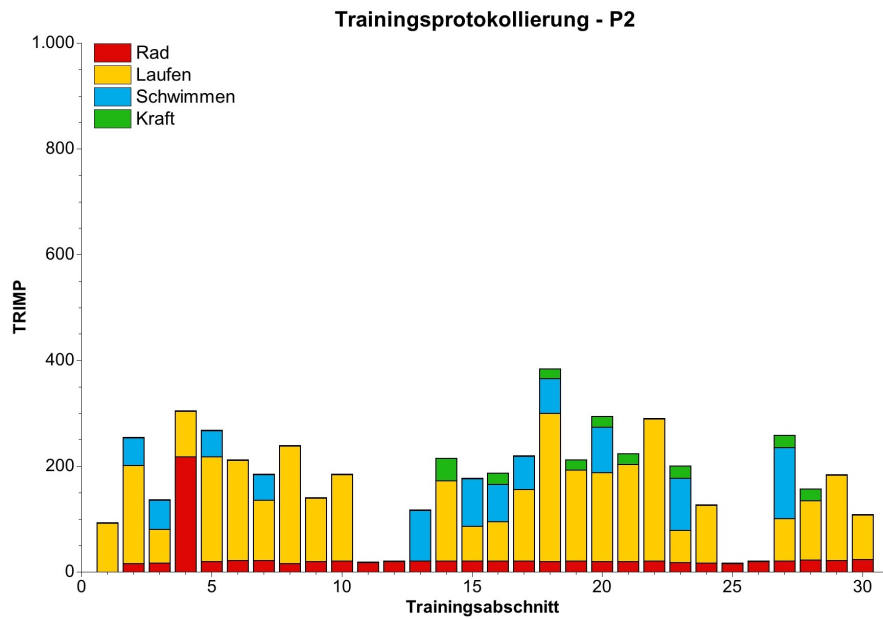
### 5.1.1 Trainingsprotokollierung

Die Abbildungen 5.1 - 5.3 stellen den Verlauf des Trainings der Versuchspersonen dar. Für jeden Trainingsabschnitt ist der TRIMP über drei Tage in den vier Kategorien Rad, Laufen, Schwimmen und Kraft zusammengefasst und jeweils einzeln dargestellt. Das Training von Proband P1 weist deutliche Schwankungen auf. Da sich der Untersuchungszeitraum vor allem über die Übergangsperiode erstreckte, sind keine besonderen Phasen oder Trends im Trainingsverlauf erkennbar. Deutlich wird, dass besonders das Lauf- und Schwimmtraining mit hohen Umfängen im Vordergrund stand. Nur in vier der insgesamt 30 Trainingsabschnitten hat Proband P1 ein Krafttraining absolviert.




**Abbildung 5.1:** Kategoriale Trainingsprotokollierung Proband 1. Dargestellt sind die TRIMP einzelner Trainingsabschnitte in den Kategorien Rad, Laufen, Schwimmen und Kraft. (TRIMP = Trainingsimpuls)

Bei Proband P2 waren deutlich geringere Trainingsumfänge als bei den anderen beiden Versuchspersonen zu beobachten (vgl. Abbildung 5.2). In den Abschnitten 11 und 12 sowie 25 und 26 konnte P2 sein geplantes Training wegen einer Erkrankung nicht durchführen. Auffällig ist darüber hinaus, dass P2 vorwiegend ein Lauftraining absolviert hat. Mit deutlich geringeren Umfängen hat P2 sein



**Abbildung 5.2:** Kategoriale Trainingsprotokollierung Proband 2. Dargestellt sind die TRIMP einzelner Trainingsabschnitte in den Kategorien Rad, Laufen, Schwimmen und Kraft. (TRIMP = Trainingsimpuls)



**Abbildung 5.3:** Kategoriale Trainingsprotokollierung Proband 3. Dargestellt sind die TRIMP einzelner Trainingsabschnitte in den Kategorien Rad, Laufen, Schwimmen und Kraft. (TRIMP = Trainingsimpuls)

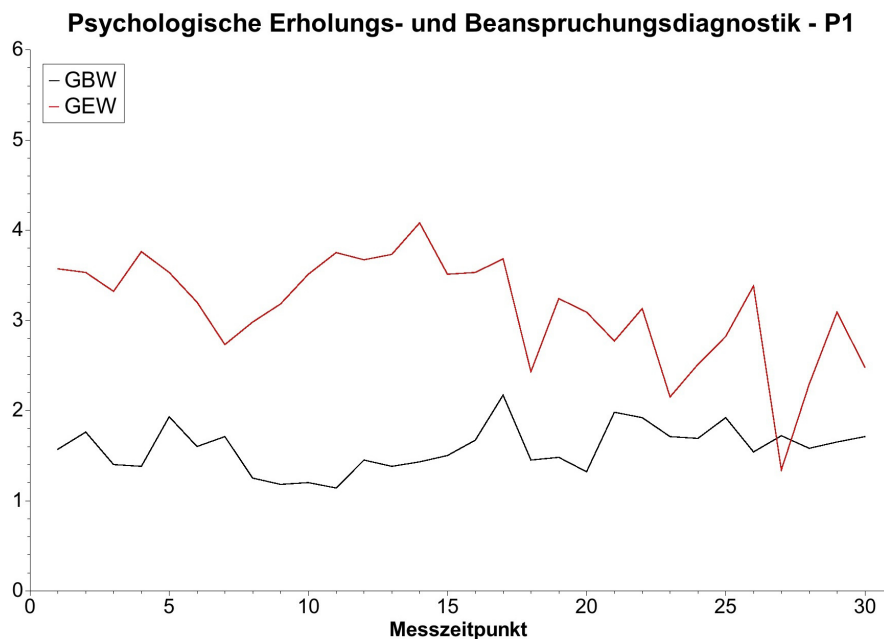
Schwimm- und Krafttraining durchgeführt. Lediglich im vierten Trainingsabschnitt hat P2 über die regelmäßigen Fahrrad-Ergometrien hinaus eine Rad-Trainingseinheit absolviert. Auch bei Proband P2 fiel der Untersuchungszeitraum mit der Übergangsperiode zusammen. In Vorbereitung auf die weiteren

Trainingsabschnitte hat P2 daher erst in der zweiten Hälfte mit einem Krafttraining begonnen.

Den höchsten Trainingsumfang hat Proband P3 absolviert (vgl. Abbildung 5.3). Dabei wurden vor allem im Radtraining mit einem durchschnittlichen TRIMP von  $188 \pm 90$  die insgesamt höchsten Umfänge innerhalb einzelner Trainingsabschnitte absolviert, wobei alle anderen Trainingsformen ebenso berücksichtigt wurden. Da Proband P3 kein aktiver Wettkampfsportler ist, wurden in der Trainingsplanung keine Periodisierungsmodelle umgesetzt. Somit ergeben sich in den einzelnen Trainingsabschnitten auch deutliche Schwankungen bei der Höhe der Gesamtbelastungen. Zum Ende des Untersuchungszeitraums ist eine geringe Abnahme der Trainingsbelastungen beobachtbar.


### 5.1.2 Psychologische Erholungs- und Beanspruchungsdiagnostik

Die eingangs dieses Kapitels beschriebenen höheren Gesamterholungswerte der psychologischen Erholungs- und Beanspruchungsdiagnostik sind vor allem bei den Probanden P1 und P3 in der Verlaufsanalyse deutlich erkennbar (vgl. Abbildungen 5.4 - 5.6). Bei Proband P1 bleibt der Gesamtbelastungswert auf einem recht konstanten und niedrigen Niveau. Der GEW ist deutlich höher und auch durch eine größere Variabilität gekennzeichnet. In der zweiten Hälfte des Untersuchungszeitraums weist der GEW bei P1 einen abnehmenden Trend auf.




**Abbildung 5.4:** Zeitreihen der psychologische Erholungs- und Beanspruchungsdiagnostik von Proband P1. (GBW = Gesamtbelastungswert; GEW = Gesamterholungswert)

Auch bei Proband 2 schwankt der Gesamtbelastungswert nur gering um einen Wert von ca. 2 (vgl. Abbildung 5.5). Der ebenfalls höhere Gesamterholungswert zeigt deutliche Schwankungen zwischen



**Abbildung 5.5:** Zeitreihen der psychologische Erholungs- und Beanspruchungsdiagnostik von Proband P2. (GBW = Gesamtbelastungswert; GEW = Gesamterholungswert)



**Abbildung 5.6:** Zeitreihen der psychologische Erholungs- und Beanspruchungsdiagnostik von Proband P3. (GBW = Gesamtbelastungswert; GEW = Gesamterholungswert)

einem Wert von 2,6 und 4,8. Trends sind im zeitlichen Verlauf bei beiden Werten der Erholungs- und Beanspruchungsdiagnostik nicht zu erkennen. Deutlich ist jedoch die Abnahme des GEW zu




den Zeitpunkten beobachtbar, an denen der Proband P2 krank war und nicht trainieren konnte. Der Einfluss der Erkrankungen auf den GBW zeigt sich in der Zeit um Messzeitpunkt 24.

Der Zeitverlauf des GBW und GEW unterliegt bei Proband 3 deutlich geringeren Schwankungen, die zudem über den Untersuchungszeitraum kleiner werden. Bis zum Messzeitpunkt 10 liegt der GEW immer etwas über dem GBW. Ab diesem Zeitpunkt nähern sich beide Größen einem Wert von ca. 2,5 an. Während sich der GBW von Beginn bis zum Ende nur gering verändert, nimmt der GEW von anfangs 3,5 auf 2,1 ab.

### 5.1.3 Leistungsdiagnostik


Die Abbildungen 5.7 - 5.9 zeigen die Entwicklungen der  $VO_2\text{max}$  und die berechneten linearen Trends im Zeitverlauf. Bei allen Probanden ist eine leichte Abnahme der Leistungsfähigkeit über den Untersuchungszeitraum feststellbar. Die Leistungswerte schwanken bei Proband P1 nur gering. Die Leistungsfähigkeit nimmt von Messzeitpunkt 1 zu Messzeitpunkt 30 um  $0,18 \text{ l}\cdot\text{min}^{-1}$  ab. Die Steigung der Regressionsgeraden beträgt  $-0,0055$ .




**Abbildung 5.7:** Leistungsdiagnostik Proband P1. Zeitreihe des Verlaufs der  $VO_2\text{max}$  von Proband P1 und lineare Trendanpassung. ( $VO_2\text{max}$  = maximale Sauerstoffaufnahme)

Bei Proband P2 zeigt sich im Vergleich vom Anfang zum Ende der Untersuchung nur eine geringe Veränderung der Leistungsfähigkeit von  $0,06 \text{ l}\cdot\text{min}^{-1}$ . Zwischenzeitlich nimmt die  $VO_2\text{max}$  aber auf einen Wert von  $3,22 \text{ l}\cdot\text{min}^{-1}$  zum Messzeitpunkt 24 ab. Dieser Rückgang fällt mit der bereits beschriebenen Erkrankung von P2 zusammen. Nach der deutlichen Leistungsabnahme nimmt die  $VO_2\text{max}$

aber auch innerhalb von sechs Tagen wieder deutlich zu. Dennoch ist die größere negative Steigung der Regressionsgeraden von  $-0,0078$  in Verbindung mit der Erkrankung zu bringen.

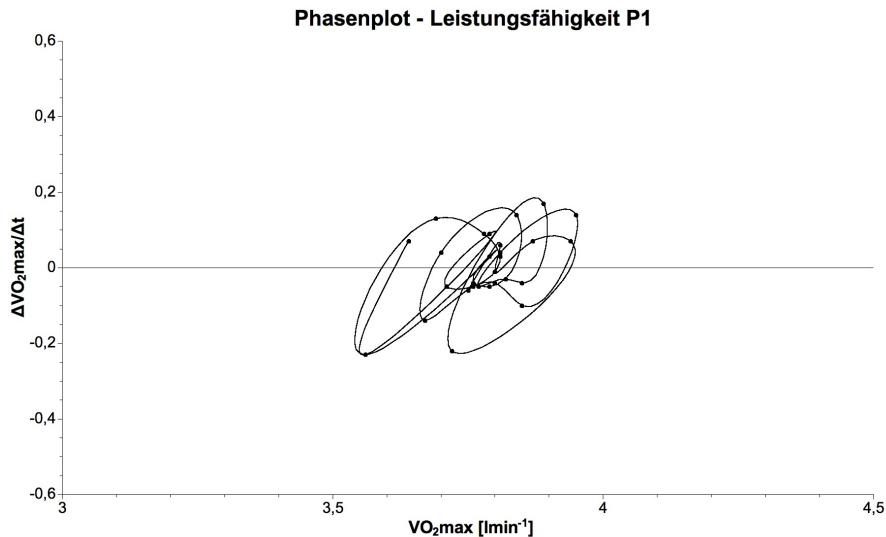


**Abbildung 5.8:** Leistungsdiagnostik Proband P2. Zeitreihe des Verlaufs der VO<sub>2</sub>max von Proband P2 und lineare Trendanpassung. (VO<sub>2</sub>max = maximale Sauerstoffaufnahme)

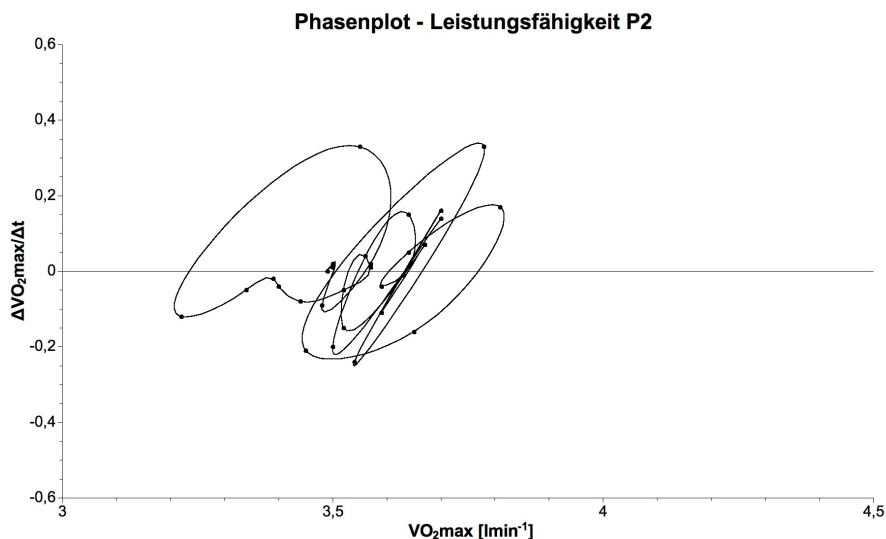


**Abbildung 5.9:** Leistungsdiagnostik Proband P3. Zeitreihe des Verlaufs der VO<sub>2</sub>max von Proband P3 und lineare Trendanpassung. (VO<sub>2</sub>max = maximale Sauerstoffaufnahme)

Proband P3 ist als leistungsstärkste Versuchsperson zu bezeichnen. Der höchste gemessen Wert der  $VO_2\max$  beträgt bei P3  $4,17 \text{ l}\cdot\text{min}^{-1}$ . Die Leistungsfähigkeit nimmt jedoch zum Ende um  $0,17 \text{ l}\cdot\text{min}^{-1}$  gegenüber dem Ausgangswert ab. Die Steigung der linearen Trendanpassung beträgt  $-0,0068$ . Bei Proband P3 zeigen sich auch große Schwankungen zwischen dem Maximalwert von  $4,17 \text{ l}\cdot\text{min}^{-1}$  und dem Minimalwert von  $3,60 \text{ l}\cdot\text{min}^{-1}$ .



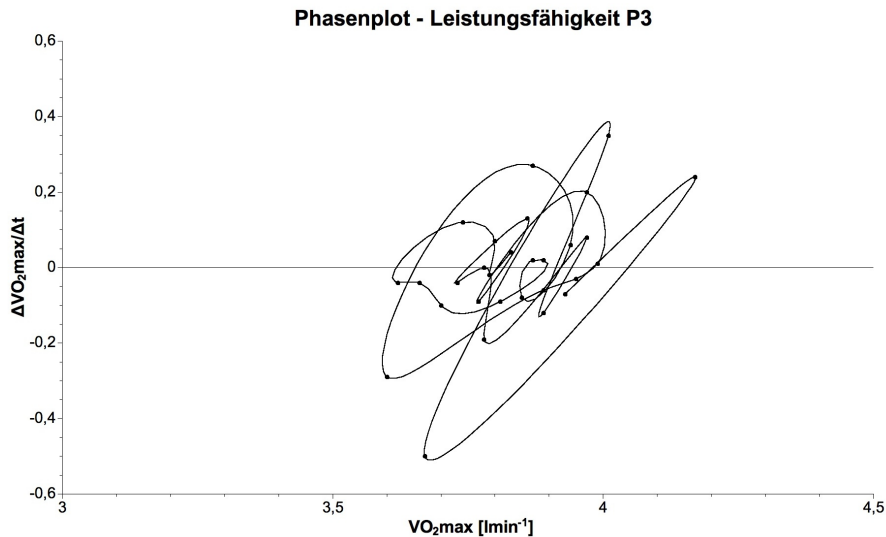
**Abbildung 5.10:** Phasenplot des Leistungsverlaufs von Proband P1. Die Veränderung der maximalen Sauerstoffaufnahme  $\Delta VO_2\max/\Delta t$  ist gegenüber der Leistungsfähigkeit  $VO_2\max$  aufgetragen.



**Abbildung 5.11:** Phasenplot des Leistungsverlaufs von Proband P2. Die Veränderung der maximalen Sauerstoffaufnahme  $\Delta VO_2\max/\Delta t$  ist gegenüber der Leistungsfähigkeit  $VO_2\max$  aufgetragen.

Für die Bewertung der zeitlichen Stabilität wurde in Phasenplots die Veränderung der Leistungsfähigkeit ( $\Delta VO_2\max/\Delta t$ ) gegenüber der Leistungsfähigkeit ( $VO_2\max$ ) aufgetragen (vgl. Abbildungen

5.10 - 5.12). Bei allen Probanden sind stabile Systemzustände zu beobachten. Bei den P2 und P3 sind zwar einzelne deutliche Schwankungen erkennbar, dennoch lassen sich keine unterschiedlichen Zustände eindeutig abgrenzen.



**Abbildung 5.12:** Phasenplot des Leistungsverlaufs von Proband P3. Die Veränderung der maximalen Sauerstoffaufnahme  $\Delta VO_2\max/\Delta t$  ist gegenüber der Leistungsfähigkeit  $VO_2\max$  aufgetragen.

## 5.2 Empirische Modellprüfung

### 5.2.1 Modellanpassung und -prüfung


Die Ergebnisse der Analyse und Prognose von Trainingswirkungen mit künstlichen neuronalen Netzen sind für alle Probanden in Tabellen 5.2 - 5.4 sowie Abbildung 5.13 - 5.15 dargestellt. Die Modellanpassung und die Prognoseleistung werden jeweils für die unterschiedlichen Lernverfahren und Trainingsparameter gesondert angegeben.

Die beste Modellanpassung wird bei Proband P1 mit dem RPROP-Lernverfahren erreicht. Die höchste Prognoseleistung ergibt sich beim Einsatz des Backpropagation mit Momentum Verfahren für das Modelltraining und der Kombination des Lernparameters  $\eta=0,9$  mit dem Momentum-Parameter  $\mu=0,5$ . Da hiermit zudem die zweitbeste Modellanpassung erreicht wird, wurden bei Proband P1 diese Modellparameter für die weiteren Darstellungen, Analysen und den Modellvergleich übernommen.

Die Abbildung 5.13 zeigt den originalen Leistungsverlauf des Probanden P1, den modellierten Verlauf über die Trainingsphase und die Simulation der Leistungsentwicklung über den Prognosezeitraum. Die Simulation für die ersten drei Zeitpunkte der Simulation zeigt eine sehr gute Prognose mit geringen Abweichungen. Eine höhere Leistungsfähigkeit wird für den vierten Zeitpunkte vorhergesagt.

**Tabelle 5.2:** Modellparameter, Modellgüte und Prognoseleistung der simulativen Trainingswirkungsanalyse mit dem KNN-Modell Proband P1. (TA = Trainingsalgorithmus; RPROP = Resilient Propagation;  $\eta$  = Lernparameter;  $\mu$  = Momentum-Parameter; MSE = mean square error; RMSE = root mean square error;  $r^2$  = Determinationskoeffizient)

Modellparameter			Modellanpassung			Prognoseleistung	
TA	$\eta$	$\mu$	MSE	RMSE	$r^2$	MSE	RMSE
Backpropagation mit Momentum	0,1	0,1	0,00	0,03	0,86	0,01	0,11
	0,1	0,5	0,00	0,04	0,83	0,01	0,09
	0,1	0,9	0,00	0,03	0,90	0,02	0,14
	0,5	0,1	0,00	0,05	0,71	0,02	0,14
	0,5	0,5	0,00	0,06	0,74	0,04	0,20
	0,5	0,9	0,00	0,05	0,72	0,02	0,15
	0,9	0,1	0,00	0,05	0,72	0,03	0,17
	0,9	0,5	0,00	0,03	0,91	0,00	0,06
	0,9	0,9	0,00	0,03	0,91	0,04	0,19
<b>RPROP</b>			0,00	0,02	0,97	0,02	0,15



**Abbildung 5.13:** Ergebnis der KNN-Modellierung für Proband P1. Es ist der zeitliche Verlauf der realen Leistungswerte (Original) und der modellierten Leistung (KNN-Modell) dargestellt. Die markierte Linie kennzeichnet die prognostizierten Leistungswerte (Simulation). (VO<sub>2</sub>max = maximale Sauerstoffaufnahme)

Bei Proband P2 wurde ebenfalls die beste Modellanpassung mit dem RPROP-Verfahren erreicht (vgl. Tabelle 5.3). Die Vorhersagegenauigkeit ist in diesem Fall aber wiederum nach einem Modelltraining mit dem BPM-Verfahren bei einer Kombination des Lernparameters  $\eta=0,9$  mit dem Momentum-Parameter  $\mu=0,9$  am höchsten. Mit diesen Modellparametern wird auch hier eine sehr gute Anpassung erreicht, weshalb sie als optimale Modellkonfiguration für die weiteren Analyseschritte ausgewählt wurden.


**Tabelle 5.3:** Modellparameter, Modellgüte und Prognoseleistung der simulativen Trainingswirkungsanalyse mit dem KNN-Modell Proband P2. (TA = Trainingsalgorithmus; RPROP = Resilient Propagation;  $\eta$  = Lernparameter;  $\mu$  = Momentum-Parameter; MSE = mean square error; RMSE = root mean square error;  $r^2$  = Determinationskoeffizient)

Modellparameter			Modellanpassung			Prognoseleistung	
TA	$\eta$	$\mu$	MSE	RMSE	$r^2$	MSE	RMSE
Backpropagation mit Momentum	0,1	0,1	0,00	0,06	0,88	0,04	0,20
	0,1	0,5	0,00	0,05	0,88	0,06	0,24
	0,1	0,9	0,00	0,05	0,88	0,05	0,23
	0,5	0,1	0,00	0,05	0,93	0,02	0,15
	0,5	0,5	0,00	0,05	0,94	0,03	0,16
	0,5	0,9	0,00	0,05	0,86	0,03	0,16
	0,9	0,1	0,00	0,04	0,94	0,02	0,15
	0,9	0,5	0,00	0,04	0,94	0,02	0,16
	0,9	0,9	0,00	0,05	0,94	0,02	0,12
<b>RPROP</b>			0,00	0,01	0,99	0,05	0,23

In Ergänzung zu Tabelle 5.3 stellt Abbildung 5.14 für Proband P2 den Polygonzug des Leistungsverlaufs sowie die modellierten und simulierten Leistungsentwicklung dar. Die Vorhersage der Leistungsfähigkeit liegt bei P2 immer über den tatsächlichen Werten. Besonders der vierte Messzeitpunkt der Prognosephase wird vom Modell deutlich überschätzt.

Bei Proband P3 zeigt sich ein vergleichbares Bild zu den beiden anderen Versuchspersonen (vgl. Tabelle 5.4). Obwohl wiederum die beste Modellanpassung mit dem RPROP-Verfahren erreicht wird, ergibt sich auch hier die geringste Abweichung der Leistungsprädiktion nach einem Netztraining mit dem BPM-Verfahren. Die optimale Modellkonfiguration mit dem Lernparameters  $\eta=0,9$  und mit dem Momentum-Parameter  $\mu=0,1$  führt bei gleichzeitig hoher Modellgüte zur besten Prognoseleistung.


Der Leistungsverlauf wird durch das KNN-Modell für Proband P3 sehr gut approximiert. Die zunehmende Leistungsfähigkeit während der Prognosephase kann das Modell in der Simulation ebenfalls



**Abbildung 5.14:** Ergebnis der KNN-Modellierung für Proband P2. Es ist der zeitliche Verlauf der realen Leistungswerte (Original) und der modellierten Leistung (KNN-Modell) dargestellt. Die markierte Linie kennzeichnet die prognostizierten Leistungswerte (Simulation). ( $VO_2\max$  = maximale Sauerstoffaufnahme)

**Tabelle 5.4:** Modellparameter, Modellgüte und Prognoseleistung der simulativen Trainingswirkungsanalyse mit dem KNN-Modell Proband P3. (TA = Trainingsalgorithmus; RPROP = Resilient Propagation;  $\eta$  = Lernparameter;  $\mu$  = Momentum-Parameter; MSE = mean square error; RMSE = root mean square error;  $r^2$  = Determinationskoeffizient)

Modellparameter			Modellanpassung			Prognoseleistung	
TA	$\eta$	$\mu$	MSE	RMSE	$r^2$	MSE	RMSE
Backpropagation mit Momentum	0,1	0,1	0,01	0,08	0,73	0,00	0,06
	0,1	0,5	0,01	0,08	0,73	0,00	0,06
	0,1	0,9	0,00	0,07	0,76	0,01	0,10
	0,5	0,1	0,00	0,06	0,83	0,00	0,06
	0,5	0,5	0,01	0,07	0,71	0,01	0,11
	0,5	0,9	0,01	0,08	0,77	0,01	0,12
	0,9	0,1	0,00	0,06	0,84	0,00	0,06
	0,9	0,5	0,00	0,07	0,77	0,01	0,10
	0,9	0,9	0,01	0,12	0,83	0,04	0,19
<b>RPROP</b>			0,00	0,01	0,99	0,02	0,13



**Abbildung 5.15:** Ergebnis der KNN-Modellierung für Proband P3. Es ist der zeitliche Verlauf der realen Leistungswerte (Original) und der modellierten Leistung (KNN-Modell) dargestellt. Die markierte Linie kennzeichnet die prognostizierten Leistungswerte (Simulation). ( $VO_2\max$  = maximale Sauerstoffaufnahme)

richtig abschätzen (vgl. Abbildung 5.15).

Für alle Probanden wurde eine Analyse und Prognose von Trainingswirkungen mit der optimalen Modellkonfiguration bei reduzierter Modellkomplexität durchgeführt (vgl. Kapitel 4.5.1). Die Ergebnisse der simulativen Trainingswirkungsanalyse mit den Modellen A und B sind in Tabelle 5.5 zusammengefasst. Für Modell A zeigt sich bei allen Probanden eine Abnahme der Modellgüte. Bei Proband P2 führt die Reduktion der Modellkomplexität zu einer deutlich verringerten Modellanpassung an den originalen Leistungsverlauf. Mit der Abnahme der Modellgüte nimmt bei Modell A auch weitgehend die Prognosegenauigkeit ab. Lediglich bei Proband P3 ist eine minimale Zunahme der Prognoseleistung zu beobachten.

Die weitere Reduktion der Modellkomplexität in Modell B führt bei den Probanden P1 und P3 auch zu einer weiteren Abnahme der Modellgüte. Bei Proband P2 nehmen die Werte der Fehlermaße gegenüber der Modellierung mit Modell A leicht ab und der Determinationskoeffizient als Zusammenhangsmaß etwas zu. Die Güte der Modellanpassung bleibt aber für das Modell B bei allen Versuchspersonen unter den Werten des Gesamtmodells. Die weitere Komplexitätsreduktion wirkt sich nicht weiter negative auf die Vorhersagegenauigkeit der Leistungsfähigkeit aus. Im Vergleich zu Modell A zeigen sich bei den Probanden P1 und P2 etwas geringere Abweichungswerte, während sich bei P2 der RMSE etwas erhöht. Insgesamt bleibt die Prognoseleistung aber gegenüber dem Gesamt-Modell auf einem niedrigeren Niveau.



**Tabelle 5.5:** Modellgüte und Prognoseleistung bei reduzierter Modellkomplexität. Dargestellt sind die Ergebnisse der Analyse und Prognose von Trainingswirkungen im Vergleich mit dem Gesamt-Modells, mit Modell A und mit Modell B. (MSE = mean square error; RMSE = root mean square error;  $r^2$  = Determinationskoeffizient)

Modell	Proband	Modellanpassung			Prognoseleistung	
		MSE	RMSE	$r^2$	MSE	RMSE
Gesamt-Modell	P1	0,00	0,03	0,91	0,00	0,06
	P2	0,00	0,05	0,94	0,02	0,12
	P3	0,00	0,06	0,84	0,00	0,06
Modell A	P1	0,01	0,09	0,63	0,04	0,20
	P2	0,01	0,19	0,43	0,07	0,26
	P3	0,01	0,08	0,66	0,00	0,05
Modell B	P1	0,00	0,07	0,56	0,02	0,16
	P2	0,01	0,11	0,62	0,02	0,15
	P3	0,01	0,10	0,58	0,01	0,10

### 5.2.2 Modellvergleich


Die Modellgüte und Prognoseleistung der simulativen Trainingswirkungsanalyse wird im Vergleich zu den anerkannten und vielfach eingesetzten antagonistischen Modellen bewertet. Die Modelle wurden mit den Datensätzen der Trainingsphase kalibriert. Anschließend wurde ebenfalls die Modellgüte berechnet und die Entwicklung der Leistungsfähigkeit über den Prognosezeitraum vorhergesagt.

**Tabelle 5.6:** Modellparameter, Modellgüte und Prognoseleistung der simulativen Trainingswirkungsanalyse mit dem FF-Modell. ( $\tau_1$  und  $\tau_2$  = Abklingkonstanten der Fitness- und Fatigue-Komponente;  $k_1$  und  $k_2$  = Verstärkungsfaktoren der Fitness- und Fatigue-Komponente; MSE = mean square error; RMSE = root mean square error;  $r^2$  = Determinationskoeffizient)


Proband	Modellparameter					Modellanpassung			Prognoseleistung	
	$\tau_1$	$\tau_2$	$k_1$	$k_2$	$k_1/k_2$	MSE	RMSE	$r^2$	MSE	RMSE
P1	41	20	0,000	0,013	0,00	0,01	0,08	0,13	0,02	0,14
P2	35	20	0,000	0,006	0,00	0,02	0,13	0,31	0,00	0,05
P3	60	20	0,000	0,056	0,00	0,01	0,12	0,20	0,00	0,03

In Tabelle 5.6 sind die Modellparameter, die Modellgüte und Prognoseleistung der Analyse und Pro-

gnose von Trainingswirkungen mit dem FF-Modell zusammen gefasst. Bei allen Probanden wird eine deutlich geringere Güte der Modellanpassung erreicht. Sowohl die Fehlermaße als auch der Determinationskoeffizient weisen darauf hin, dass der originale Leistungsverlauf mit dem FF-Modell nur in geringem Maß wieder gegeben werden kann.




**Abbildung 5.16:** Ergebnis der FF-Modellierung für Proband P1. Es ist der zeitliche Verlauf der realen Leistungswerte (Original) und der modellierten Leistung (KNN-Modell) dargestellt. Die markierte Linie kennzeichnet die prognostizierten Leistungswerte (Simulation). ( $VO_2\max$  = maximale Sauerstoffaufnahme)



**Abbildung 5.17:** Ergebnis der FF-Modellierung für Proband P2. Es ist der zeitliche Verlauf der realen Leistungswerte (Original) und der modellierten Leistung (KNN-Modell) dargestellt. Die markierte Linie kennzeichnet die prognostizierten Leistungswerte (Simulation). ( $VO_2\max$  = maximale Sauerstoffaufnahme)

Die Abbildungen 5.16 - 5.18 stellen den originalen und den modellierten Leistungsverlauf dar. Schwankungen im Leistungsverlauf kann das FF-Modell nicht abbilden. Das Modellergebnis ist mehr mit einer Linear- bzw. Polynomapproximation zu vergleichen. Die Trendanpassung über die Trainingsphase wird über den Prognosezeitraum fortgeführt. Mit dem FF-Modell wird für die Probanden P2 und P3 gegenüber dem KNN-Modell eine etwas bessere Prognoseleistung erreicht.

Eine Interpretation der Modellparameter ist nur eingeschränkt möglich. Bei allen Probanden liegt die Zeitkonstante  $\tau_2$  der Fatigue-Komponente am Rand des Wertebereichs. Auch die Zeitkonstante  $\tau_1$  der Fitness-Komponente nimmt hohe Werte für den Probanden P3 sogar den Maximalwert an.




**Abbildung 5.18:** Ergebnis der FF-Modellierung für Proband P3. Es ist der zeitliche Verlauf der realen Leistungswerte (Original) und der modellierten Leistung (KNN-Modell) dargestellt. Die markierte Linie kennzeichnet die prognostizierten Leistungswerte (Simulation). ( $VO_2max$  = maximale Sauerstoffaufnahme)

Die Ergebnisse der Analyse und Prognose von Trainingswirkungen mit dem PerPot-Modell werden in Tabelle 5.7 zusammengefasst und in den Abbildungen 5.19 - 5.21 dargestellt. Die Güte der Modellanpassung ist wiederum im Vergleich zur Modellierung mit KNN deutlich geringer. Kurzfristige Schwankungen im Leistungsverlauf werden nur näherungsweise bei Proband P2 abgebildet. Der Determinationskoeffizient erreicht für die Beschreibung des Zusammenhangs zwischen originalen mit dem modellierten Leistungsverlauf für P1 nur ein sehr geringes Niveau. Das PerPot-Modell kann auch nur mit etwas geringerer Genauigkeit die Entwicklung der Leistungsfähigkeit der Probanden P1 und P3 vorhersagen. Für P2 erreicht das PerPot-Modell ein leicht verbesserte Prognoseleistung.


**Tabelle 5.7:** Modellparameter, Modellgüte und Prognoseleistung der simulativen Trainingswirkungsanalyse mit dem PerPot-Modell. (DS und DR = Verzögerungskonstanten des Strain- und Response-Potentials; MSE = mean square error; RMSE = root mean square error;  $r^2$  = Determinationskoeffizient)

Proband	Modellparameter			Modellanpassung			Prognoseleistung	
	DS	DR	DS/DR	MSE	RMSE	$r^2$	MSE	RMSE
P1	2,8	1,6	1,75	0,01	0,08	0,10	0,02	0,14
P2	2,0	2,7	0,74	0,01	0,11	0,34	0,01	0,11
P3	1,5	2,6	0,58	0,02	0,13	0,21	0,01	0,11


Die Modellparameter DS und DR weisen nur eine geringe Streuung auf und liegen in einem physiologisch sinnvoll interpretierbaren Bereich. Das Verhältnis von DS zu DR ist nur bei Proband P1 kleiner 1. Bei P2 und P3 ist das Verhältnis der Verzögerungskonstanten mit 0,74 bzw. 0,58 größer 1. Im Vergleich der beiden antagonistischen Modelle sind anhand der Fehler- und Zusammenhangsmaße geringe Unterschiede in der Modellgüte feststellbar. Bei einer Interpretation der visualisierten Zeitreihen scheint aber das PerPot-Modell Schwankungen im Signalverlauf besser abzubilden. Eine höhere Vorhersagegenauigkeit erreicht hingegen das FF-Modell vor allem bei den Probanden P2 und P3.



**Abbildung 5.19:** Ergebnis der PerPot-Modellierung für Proband P1. Es ist der zeitliche Verlauf der realen Leistungswerte (Original) und der modellierten Leistung (KNN-Modell) dargestellt. Die markierte Linie kennzeichnet die prognostizierten Leistungswerte (Simulation). ( $VO_{2max}$  = maximale Sauerstoffaufnahme)



**Abbildung 5.20:** Ergebnis der PerPot-Modellierung für Proband P2. Es ist der zeitliche Verlauf der realen Leistungswerte (Original) und der modellierten Leistung (KNN-Modell) dargestellt. Die markierte Linie kennzeichnet die prognostizierten Leistungswerte (Simulation). (VO<sub>2</sub>max = maximale Sauerstoffaufnahme)



**Abbildung 5.21:** Ergebnis der PerPot-Modellierung für Proband P3. Es ist der zeitliche Verlauf der realen Leistungswerte (Original) und der modellierten Leistung (KNN-Modell) dargestellt. Die markierte Linie kennzeichnet die prognostizierten Leistungswerte (Simulation). (VO<sub>2</sub>max = maximale Sauerstoffaufnahme)

# Kapitel 6

## Diskussion

### 6.1 Empirische Einzelfallanalysen

Bei der individuellen Trainingsgestaltung sind zwei Merkmale für die Analyse und Prognose des Zusammenhangs zwischen Training und der spezifischen Ausdauerleistungsfähigkeit von besonderer Bedeutung. Neben unterschiedlichen Trainingsformen hat der Trainingsumfang einen Einfluss auf die Trainingswirkungen. Über den gesamten Untersuchungszeitraum sind dabei deutliche Unterschiede im interindividuellen Vergleich zu beobachten. Während vor allem Proband P2 mit einem durchschnittlichen Gesamt-TRIMP von  $181 \pm 91$  im Rahmen der Übergangsperiode deutlich geringere Umfänge in den einzelnen Trainingsabschnitten durchgeführt hat, absolvierte Proband P3 sein Training mit teilweise sehr hohen Einzelbelastungen und einem durchschnittlichen Gesamt-TRIMP von  $375 \pm 193$ . Deutliche Abweichungen sind auch in der Schwerpunktsetzung der einzelnen Trainingsformen zu beobachten. Während Proband P3, der nicht mehr aktiv an Wettkämpfen teilnimmt, mit allen Trainingsformen seine triathlonspezifische Leistungsfähigkeit aufrecht erhalten wollte, entspricht die inhaltliche Gestaltung bei den Probanden P1 und P2 den Vorgaben der Trainingskonzeption im Triathlon (DTU, 2003).

Bei der psychologischen Erholungs- und Beanspruchungsdiagnostik sind vor allem die stabilen Werte des Gesamtbelastungszustands und die deutlichen Schwankungen des Gesamterholungswerts auffällig. Diese Ergebnisse decken sich aber mit den theoretischen Annahmen der psychologischen Erholungs- und Beanspruchungsforschung. Demnach ist der aktuelle Beanspruchungszustand von den Bewältigungsmöglichkeiten und -fähigkeiten einer Person bestimmt. Solange die Bewältigungsressourcen ausreichend sind, können Belastungen ausgeglichen und die Auswirkungen auf die wahrgenommene Beanspruchung reduziert werden (Schlicht, 1992). Erholung ist ein vielschichtiger (physiologischer, psychologischer und sozialer) Prozess, der unmittelbar sowohl durch intentionale Regenerationsmaßnahmen als auch durch autonome Erholungsaktivitäten beeinflusst wird (Kellmann & Kallus, 2000). Da kein Zusammenhang zwischen Gesamt-TRIMP und GBW festgestellt werden konnte, ist anzunehmen, dass die verhältnismäßig geringen Trainingsbelastungen zu keinen besonderen Störungen des Beanspruchungszustands geführt haben (P1:  $r^2 = 0,03$ ; P2:  $r^2 = 0,01$ ; P3:  $r^2 = 0,00$ ). Für

eine ressourcenabhängige Belastungsbewältigung spricht auch, dass bei Proband P2 die erste kürzere Krankheitsphase zu keiner relevanten Zunahme des GBW geführt hat. Eine deutliche Zunahme der wahrgenommenen Beanspruchung stellte sich jedoch während der zweiten, längerfristigen Krankheit ein, für die wahrscheinlich die vorhandenen Ressourcen dann nicht mehr ausreichend waren. Der vergleichsweise niedrige GEW von Proband P3 erklärt sich möglicherweise durch eine hohe Gesamtbelastung vor allem im Beruf und im privaten Umfeld. Hier kann die Varianz des GEW auch nur in geringem Maße durch den Gesamt-TRIMP aufgeklärt werden ( $r^2 = 0,05$ ). Ein etwas engerer Zusammenhang zwischen Gesamt-TRIMP und GEW besteht bei den beiden anderen Versuchspersonen (P1:  $r^2 = 0,27$ ; P2:  $r^2 = 0,25$ ). Damit erklären sich auch teilweise die großen Schwankungen, die in beiden Variablen zu beobachten sind.

Die Abnahme der Leistungsfähigkeit über den gesamten Untersuchungszeitraum ist bei den Probanden P1 und P2 auf die reduzierten Trainingsbelastungen in der Übergangsperiode zurückzuführen. Am deutlichsten fällt die Leistungsabnahme bei Proband P2 aus, bei dem zwar vom ersten bis zum letzten Messtermin die geringste absolute Leistungsabnahme feststellbar ist, die Trendgerade aber die größte negative Steigung zeigt. Wobei dies auch auf die beiden Krankheitsphasen zurück zu führen ist, die vor allem zum Messzeitpunkt 24 mit einer sehr deutlich reduzierten  $VO_{2max}$  einhergehen. Durch besondere Ereignisse oder spezifische Trainingsvorgaben kann die Abnahme der Leistungsfähigkeit bei Proband P3 nicht erklärt werden. In Frage kommen möglicherweise die bereits diskutierten hohen Gesamtbelastungen und die damit verbundenen gestörten Erholungsprozesse.

Eine Zeitreihenprognose setzt eine gewisse Stabilität des Systemzustands voraus. Damit diese Bedingung geprüft werden kann, wurde der Leistungsverlauf für alle Probanden in Phasenplots dargestellt (vgl. Abbildungen 5.10 - 5.12). Obwohl sich bei den Probanden P2 und P3 gegenüber Proband P1 deutlich größere Schwankungen darstellen, sind bei keiner Versuchsperson Phasenübergänge oder eindeutig abgrenzbare Systemzustände zu erkennen. Somit kann man von stabilen Systemzuständen ausgehen, sodass die wesentliche Voraussetzung für Zeitreihenprognosen erfüllt ist.

## 6.2 Empirische Modellprüfung

Im Original-Modell-Vergleich zeigt sich, dass den künstlichen neuronalen Netzen mit der gewählten Topologie und den gewählten Modellparametern die Zuordnung von Eingabe- und Ausgabedaten trainiert werden kann. Das RPROP-Verfahren führt dabei zur besten Modellanpassung mit durchschnittlichen Abweichungswerten von  $0,01 - 0,02 \text{ l}\cdot\text{min}^{-1}$ . Insgesamt wird mit dem BPM-Trainingsalgorithmus eine etwas geringere Genauigkeit erreicht ( $0,04 \leq \text{RMSE} \leq 0,12 \text{ l}\cdot\text{min}^{-1}$ ). Die optimale Anpassung der modellierten Leistungsfähigkeit an den originalen Leistungsverlauf ergibt sich mit dem BPM-Verfahren für jeden Probanden bei unterschiedlichen Modellparametern und liegt im Durchschnitt bei einem RMSE von  $0,05 \text{ l}\cdot\text{min}^{-1}$ . Betrachtet man die durchschnittlichen Determinationskoeffizienten der Modellanpassung ( $r^2 = 0,98$  bzw.  $r^2 = 0,90$ ) und vergleicht diese mit den Ergebnissen anderer Arbeiten

(vgl. Kapitel 2.4.1.1 und 2.4.1.2), wird der Leistungsverlauf mit dem KNN-Modell überwiegend besser abgebildet.

Die Fähigkeit zur Generalisierung spiegelt sich in der Prognoseleistung des KNN-Modells wider. Obwohl mit dem RPROP-Verfahren eine bessere Modellanpassung erreicht wird, ist die Vorhersagegenauigkeit nach einem Netztraining mit dem BPM-Verfahren höher. In den Tabellen 5.2 - 5.4 ist jeweils die Konfiguration von Modellparametern gekennzeichnet, mit der gleichzeitig die optimale Prognoseleistung und Modellanpassung erreicht wird. Dabei ist der BPM-Algorithmus bei allen Versuchspersonen das am besten geeignete Verfahren für das Netztraining. Die durchschnittliche Abweichung der prognostizierten Leistungswerte vom originalen Leistungsverlauf beträgt  $0,08 \text{ l} \cdot \text{min}^{-1}$ . Dies entspricht einer mittleren Abweichung von 2,2 %. Vergleicht man diese Ergebnisse wiederum mit der Vorhersagegenauigkeit weiterer Verfahren, zeigen sich bei anderen Untersuchungen meistens deutlich größere Abweichungen. Einzig bei der Arbeit von Ganter et al. (2006) wurden über einen etwas kürzeren Prognosezeitraum von acht Tagen vergleichbare Resultate mit einer durchschnittlichen Abweichung von 2,4 % bei zehn Versuchspersonen erreicht.

Diese Ergebnisse zeigen, dass es nach einer individuellen Modellkalibrierung möglich ist, mit einem zeitabhängigen und multivariaten Trainingswirkungsmodell auf der Basis künstlicher neuronaler Netze die Entwicklung der Ausdauerleistungsfähigkeit im Triathlon mit einer hohen Genauigkeit abzubilden und ihren Verlauf über einen begrenzten Zeitraum vorherzusagen. Zu berücksichtigen ist jedoch, dass KNN anhand von (Daten-) Beispielen zunächst ihre Prognosefähigkeit erlernen müssen. Die vorhandene Datenbasis für das Netztraining beeinflusst entscheidend den möglichen Grad der Verallgemeinerung. Daher sind im Rahmen dieser Arbeit bei der Ergebnisinterpretation der spezifische Modellgegenstand, der begrenzte Untersuchungszeitraum und die Charakteristik der Trainingsphasen zu berücksichtigen. Schlussfolgerungen über das Modellverhalten eines trainierten neuronalen Netzes zur Analyse und Prognose von Trainingswirkungen in anderen Sportarten sind nicht möglich. Es können auch keine Aussagen darüber getroffen werden, wie sich das Modell in Phasen mit abweichender Belastungsdynamik und Leistungsentwicklung verhält.

Die Struktur des KNN-Modells leitet sich aus der theoretischen Begründung des systemdynamischen Modells des Trainings ab. Die Entwicklung der Leistungsfähigkeit wird demnach nicht nur differenziert über die trainingsinduzierte Beanspruchung erklärt, sondern vielmehr wird der allgemeine Erholungs- und Beanspruchungszustand des Athleten als weiterer Prädiktor berücksichtigt. Welchen Einfluss die Zunahme der Modellkomplexität auf die Güte der Modellanpassung und die Prognoseleistung hat, ist Gegenstand der **Fragestellung 1**. Darüber hinaus muss auch beurteilt werden, ob sich Hinweise für die Gültigkeit der theoretischen Annahmen des systemdynamischen Modells des Trainings ergeben (**Fragestellung 2**).

Hierfür wurde schrittweise die Struktur des KNN-Modells wieder vereinfacht. Im Modell A wurden die Beanspruchungswirkungen einzelner Trainingsformen nicht mehr differenziert betrachtet, sondern zu einem Gesamt-TRIMP zusammengefasst. Im zweiten Schritt wurde dann nur noch der Zusammenhang zwischen der globalen Trainingsbeanspruchung und der Leistungsentwicklung abgebildet (Modell B).



Die Abnahme der Modellkomplexität führt bei allen Probanden zu einer geringeren Güte der Modellanpassung im Vergleich zum Gesamt-Modell. In Abhängigkeit von der schrittweisen Komplexitätsreduktion zeigt sich bei den Probanden P1 und P2 eine graduelle Abnahme der Abbildungsleistung. Bei P2 nimmt die Güte der Modellanpassung vom Gesamt-Modell zu Modell A zuerst deutlich ab ( $\Delta \text{RMSE} = 0,14 \text{ l}\cdot\text{min}^{-1}$ ) und ist bei Modell B wieder etwas höher. Mit der Abnahme der Modellkomplexität verringert sich auch weitgehend die Vorhersagegenauigkeit. Die durchschnittliche Abweichung erhöht sich bei Modell A zuerst von 2,2 % auf 4,6 % und nimmt dann bei Modell B bei einem Wert von 3,7 % wieder leicht ab.

Dies zeigt, dass mit einer abnehmenden Anzahl an Input-Variablen des künstlichen neuronalen Netzes die Zuordnung eines Eingabemusters zu einem Ausgabewert nicht mehr in gleichem Maße geleistet werden kann. Daraus ist zu schlussfolgern, dass die Entwicklung der Ausdauerleistungsfähigkeit anhand differenzierter, trainingsinduzierter Beanspruchungswirkungen sowie einer subjektiven Einschätzung des allgemeinen Erholungs- und Beanspruchungszustand besser erklärt werden kann. Eine Aggregation von Inputdaten und die Reduktion der Modellkomplexität führt zu einem geringeren Erklärungswert des Modells.

Aus diesen Ergebnissen leiten sich auch Anhaltspunkte ab, die die theoretischen Annahmen zum systemdynamischen Modell des Trainings stützen. Die Leistungsentwicklung bzw. das Systemverhalten kann nicht ausschließlich über die Wirkung kumulierter Trainingsbelastungen begründet werden. Dies ist jedoch ein wesentliches Strukturmerkmal anderer Modelle des Trainings, wie z.B. der kybernetischen Betrachtungsweise oder dem Belastungs-Beanspruchungs-Modell (Carl, 1983; Schnabel et al., 2005). Es zeigt sich vielmehr, dass der tatsächliche Beanspruchungszustand eines Athleten als Kontrollparameter die Veränderung der Leistungsfähigkeit initiiert. Hierfür müssen alle physischen, psychischen und sozialen Belastungen sowie Erholungsmaßnahmen berücksichtigt werden.

Ob sich daraus auch Implikationen für die Struktur von Trainings-Wirkungs-Modellen ergeben, kann erst im Vergleich zu anderen Ansätzen beantwortet werden. Dieser Aspekt und die Frage, ob der Trainingsprozess durch ein dynamisches Systemverhalten besser beschrieben werden kann, sind Gegenstand der Diskussion im folgenden Abschnitt.

### 6.3 Modellvergleich

Die Modellanpassung und Prognoseleistung des KNN-Modells wurde bereits im Vergleich mit den Ergebnissen anderer Arbeiten bewertet. Ein direkter Vergleich ist aber aufgrund unterschiedlicher Untersuchungsansätze und des Studiendesigns nicht möglich. Daher wurde im Rahmen dieser Arbeit das FF-Modell und das PerPot-Modell vergleichend eingesetzt. Mit diesen Modellen wurde in gleicher Weise der Trainingsprozess der Versuchspersonen analysiert und die Leistungswerte der letzten vier Messzeitpunkte prognostiziert. Wegen der bivariaten Modellstruktur war es hierfür jedoch eine notwendige Voraussetzung, die Trainingsimpulse der verschiedenen Trainingsformen zu einem Gesamt-TRIMP

zusammen zu fassen.

Mit dem FF-Modell zeigt sich bei allen Versuchspersonen nur eine sehr ungenaue Modellanpassung über die Trainingsphase. Der mittlere Determinationskoeffizient ist  $r^2 = 0,21$ . Die Abbildungen 5.16 - 5.18 verdeutlichen, dass das FF-Modell annähernd eine lineare Anpassung liefert. Damit liegt die Güte der Modellanpassung unterhalb der Ergebnisse einer Reihe anderer empirischer Studien. Ganter (2009) stellt aber bspw. in seiner Arbeit eine interindividuell sehr heterogene Modellanpassung fest, die teilweise vergleichbar mit den Resultaten dieser Untersuchung sind. Eine sinnvolle Interpretation der Modellparameter ist bei allen Probanden kaum möglich. Die mangelnde Abbildungsleistung des FF-Modells und die inhaltlich nicht interpretierbaren Modellparameter stützen die kritischen Betrachtungen einiger Autoren, die eine Anwendbarkeit des Modells in Frage stellen (Hellard et al., 2006; Pfeiffer & Perl, 2009).

Mit einer mittleren Abweichung von 1,9 % erreicht das FF-Modell eine sehr hohe Prognosegenauigkeit. Dies ist aber weniger auf die exakte Abbildung des Leistungsverlaufs zurück zu führen, sondern hängt vielmehr mit der beinahe linearen Modellanpassung zusammen. Vor allem bei den Probanden P2 und P3 können durch die lineare Abschätzung die geringen Leistungsschwankungen während der Prognosephase sehr genau approximiert werden. Im Gegensatz dazu wird die kurzfristige Leistungsabnahme bei Versuchsperson P1 durch das FF-Modell nicht abgebildet. Dies führt auch zu einer deutlich höheren Abweichung von 3,7 %.

Das PerPot-Modell kann den Leistungsverlauf ebenfalls nur sehr ungenau abbilden. Der mittlere Determinationskoeffizient ist mit  $r^2 = 0,18$  im Vergleich zum FF-Modell noch etwas geringer. Dies liegt vor allem daran, dass die Abweichung bei Proband P1 besonders hoch ist und damit auch kein signifikanter Zusammenhang zwischen dem originalen sowie modelliertem Leistungsverlauf besteht. Die Entwicklung der Leistungsfähigkeit von Proband P2 wird besser durch das PerPot-Modell abgebildet. Schwankungen im Leistungsverlauf werden durch das Modell grob angenähert. Damit ist das Modellverhalten mit den Ergebnissen der Arbeit von Ganter (2009) vergleichbar. Die Verzögerungskonstanten nehmen bei der Modellkalibrierung Werte an, die mit den Modellparametern anderer Untersuchungen vergleichbar sind (Ganter, 2009; Pfeiffer & Perl, 2009). Das Verhältnis der Zeitkonstanten ist aber nur bei Proband P1 größer 1, was dem Modellverständnis entsprechend auf einen gut trainierten Zustand hindeutet. Bei P2 und P3 ist dieses Verhältnis jedoch kleiner 1, obwohl beide Versuchspersonen ebenfalls hoch trainiert sind. Damit bleibt die Interpretierbarkeit der Modellparameter weiterhin fraglich, da sich in den wenigen empirischen Arbeiten zum PerPot-Modell weitgehend uneinheitliche Ergebnisse darstellen (Ganter et al., 2006; Torrents et al., 2007; Pfeiffer & Perl, 2009; Ganter, 2009).

Die Prognoseleistung des PerPot-Modells erreicht nicht das Niveau des KNN-Modells. Die mittlere Abweichung vom originalen Leistungsverlauf beträgt 3,2 %. Damit wird eine vergleichbare Genauigkeit zur Vorhersage der Leistungsfähigkeit erreicht, die Ganter (2009) bei einer Untersuchung mit zehn Probanden im Radfahren berichtet. Die dennoch gute Vorhersagegenauigkeit ist beim PerPot-Modell ebenfalls auf die näherungsweise lineare bzw. polynomiale Approximation zurück zu führen.

Vergleicht man diese Ergebnisse und die Resultate der Analyse und Prognose von Trainingswirkungen mit dem KNN-Modell, wird mit dem multivariaten Modellansatz eindeutig eine bessere Güte der Modellanpassung erreicht. Dies ist sicherlich auch darauf zurückzuführen, dass die Abbildung der Datenmuster der Trainingsphase dem neuronalen Netz antrainiert wird. Die Kalibrierung des FF-Modells und des PerPot-Modells stellt hingegen eine entsprechende Optimierung über den gesamten Zeitraum dar. Dessen ungeachtet ergeben sich aus den unterschiedlichen Modellstrategien abweichende Ergebnisse bei der Vorhersage der Leistungsfähigkeit. Dies ist eindeutig auf die Limitierung des Modellinputs der beiden antagonistischen Ansätze zurück zu führen, wofür auch die Ergebnisse der Komplexitätsreduktion sprechen.

Durch den direkten Vergleich der unterschiedlichen Modellansätze kann die **Fragestellung 3** beantwortet werden: Ein multivariates Trainings-Wirkungs-Modell auf Basis künstlicher neuronaler Netze hat gegenüber bivariaten Modellansätzen einen höheren Erklärungswert für die Analyse eines Trainingsprozesses und die Prognose der Leistungsentwicklung. Die Gültigkeit dieser Aussage muss wiederum für den spezifischen Anwendungsfall dieser Untersuchung eingeschränkt werden.

Die Frage, ob nichtlineare Modellansätze linearen Modellen in ihrem Verhalten überlegen sind, konnte bisher durch andere Untersuchungen nicht belegt werden (Ganter et al., 2006; Pfeifer & Perl, 2009; Ganter, 2009). Durch den Modellvergleich und die Reduktion der Komplexität des KNN-Modells lässt sich diese Frage ebenfalls nicht eindeutig beantworten. Das KNN-Modell ist dem FF-Modell bei der Analyse und Prognose von Trainingswirkungen überlegen, ein wesentlicher Unterschied zwischen den beiden antagonistischen Modell kann nicht festgestellt werden. Zudem nimmt die Abbildungs- und Prognoseleistung des KNN-Modells mit reduzierter Komplexität deutlich ab, sodass kein Vorteil gegenüber einem linearen Modellansatz erkennbar ist. Abschließend ist nicht zu klären, ob die Dynamik oder die Komplexität entscheidend das Modellverhalten beeinflusst.

Sichere Hinweise für die Gültigkeit des systemdynamischen Modells des Trainings ergeben sich aus diesen Befunden nicht (**Fragestellung 4**). Zweifelsfrei konnte aber gezeigt werden, dass eine Zunahme der Modellkomplexität zu einer besseren Abbildungs- und Prognoseleistung führt. Insofern stützt dies die Vermutung, dass der Leistungsentwicklung ein komplexes und dynamisches Verhalten zugrunde liegen muss.

# Kapitel 7

## Zusammenfassung und Ausblick

Die Analyse und Prognose von Trainingswirkungen geht auf die Formulierung eines mathematischen Modells von Banister et al. (1975) zurück. Das FF-Modell leitet sich aus einem spezifischen Modellverständnis des Trainings ab, das auf zwei wesentliche Komponenten verkürzt wurde. Diese antagonistische Modellstruktur beschreibt als Reaktion auf eine Trainingsbelastung sich überlagernde positive und negative Effekte, die in der Folge zur Veränderung der Leistungsfähigkeit führen. Dieser lineare Ansatz berücksichtigt keine qualitativen oder quantitativen Veränderungen der Wirkungsrelation im Laufe des Trainingsprozesses und entspricht damit vom grundlegenden Verständnis der kybernetischen Betrachtungsweise (Carl, 1983). Das PerPot-Modell ist durch eine vergleichbare antagonistische Modellstruktur gekennzeichnet (Mester & Perl, 2000). Durch nichtlineare Modellgleichungen bildet das Meta-Modell auch die dynamischen Änderungen des Systemzustands ab. Eine Entsprechung ist damit eher zum Belastungs-Beanspruchungs-Modell zu sehen (Schnabel et al., 2005). Eine wesentliche Einschränkung beider Modelle besteht jedoch darin, dass Trainingsbelastungen zu einer globalen Inputgröße zusammengefasst werden müssen und weitere Einflussfaktoren nicht berücksichtigt werden können.

Dem gegenüber steht die Erkenntnis, dass die Leistungsentwicklung ein vielschichtiger Prozess ist, was sich in den Modellen des Trainings widerspiegeln muss. Ganzheitliche und integrative Konzepte liegen hierfür bereits von Hohmann et al. (2007) und Ganter (2009) vor. Mit der theoretischen Ableitung des systemdynamischen Modells des Trainings wurden diese Ansätze konsequent weiter verfolgt. Diese veränderte Betrachtungsweise muss außerdem die Grundlage für die Entwicklung von Methoden zur Steuerung des Trainingsprozesses sein.

Fasst man nämlich die Ergebnisse zur Analyse und Prognose von Trainingswirkungen mit den antagonistischen Modellen aus dieser Arbeit und von anderen Untersuchungen zusammen, werden keine befriedigende Abbildungs- und Prognoseleistungen erreicht. Der empirische Modellvergleich und der Komplexitätsreduktions-Ansatz sprechen dafür, dass die Ursache vor allem in der Limitierung der Prädiktorvariablen zu sehen ist. Bessere Resultate wurden nur in Studien erreicht, bei denen der Trainingsprozess von kaum trainierten Versuchspersonen in experimentellen Untersuchungen betrachtet wurde. Aufgrund des geringen Ausgangsniveaus sind deutliche Leistungssteigerungen zu erreichen, die

dann erwartungsgemäß in enger Beziehung zu den Trainingsbelastungen zu sehen sind. Kleinere Leistungsschwankungen können aber nicht alleine durch die Trainingsbelastung erklärt werden, haben aber bspw. in der unmittelbaren Wettkampfvorbereitung eine besondere Relevanz. Daher sind Modelle nötig, die in höherem Maße die Komplexität und Dynamik des Trainingsprozesses abbilden.

Die weiteren Untersuchungsergebnisse dieser Arbeit deuten darauf hin, dass künstliche neuronale Netze besonders zur verlaufsorientierten Analyse und Prognose von Trainingswirkungen geeignet sind. Der entscheidende Vorteil dieser Methode ist in der multivariaten Modellstruktur zu sehen. Durch die differenzierte Berücksichtigung trainingsinduzierter Beanspruchungen und des aktuellen Erholungs- und Beanspruchungszustand wird einerseits ein höherer Erklärungswert für die Leistungsentwicklung erreicht. Zum anderen ergeben sich daraus Hinweise, die die Gültigkeit der theoretischen Annahmen des systemdynamischen Modells bestätigen.

Die Ergebnisse dieser Arbeit müssen durch Replikationsstudien mit höheren Fallzahlen bestätigt werden. Die Anwendung des KNN-Modells muss sich drüber hinaus in Untersuchungen bewähren, in denen andere Leistungsvoraussetzungen als abhängiges Kriterium bei Trainingswirkungsanalysen betrachtet werden. In Vorbereitung hierzu ist jedoch ein großer Forschungsbedarf zu sehen, um die Strukturen von Trainingsprozessen weiterer Komponenten der Leistungsfähigkeit oder weiterer Sportarten für eine Abbildung in Modellen aufzuklären. Dazu gehört auch die Identifikation bzw. Entwicklung von beanspruchungsorientierten Indikatoren und Verfahren zur Trainingsdiagnostik.

Forschungsbedarf ist ebenso darin zu sehen, ungeachtet des „Black-Box“-Verhaltens künstlicher neuronaler Netze Informationen über kausale Beziehungen im Trainingsprozess herauszuarbeiten. Ein mögliches Vorgehen besteht darin, den zeitlichen Umfang und die zeitliche Tiefe der Prädiktor-Zeitreihen zu verändern. Aus den unterschiedlichen Ergebnissen der simulativen Trainingswirkungsanalyse mit dem KNN-Modell lassen sich dann voraussichtlich Rückschlüsse auf zeitliche Strukturen und Kausalitäten ableiten.

Insgesamt sind die Anwendungsmöglichkeiten der antagonistischen Modelle zurückhaltend zu bewerten. Die Abbildungs- und Prognoseleistung ist kaum zufriedenstellend und eine physiologische Interpretation der Modellparameter ist nicht möglich. Es ist die Einschätzung anderer Autoren zu teilen (Hellard et al., 2006; Ganter, 2009; Pfeiffer & Perl, 2009), dass beide Modell vorübergehende Leistungsschwankungen nicht hinreichend wiedergeben können und sich damit eher für die längerfristige Grobplanung von Trainingsbelastungen eignen.

Ein praktischer Einsatz des KNN-Modells ist vor allem in der kurzfristigen Trainingsplanung oder Wettkampfvorbereitung möglich. Dabei sind Szenarien denkbar, in denen das Modell im ersten Schritt über einen ausreichend langen Zeitraum individuell für jeden Athlet trainiert wird. In der Folge wird dann mit variierenden Belastungsstrukturen in einer Simulation die optimale Leistungsentwicklung ermittelt.

## Literatur

- Adya, M. & Collopy, F. (1998). How effective are neural networks at forecasting and prediction? a review and evaluation. *Journal of forecasting*, 17 (5-6), 481–495.
- Ansley, L. (2007). Triathlon. In E. M. Winter, A. M. Jones, R. C. R. Davison, P. D. Bromley & T. H. Mercer (Hrsg.), *Sport and exercise physiology testing* (S. 191–195). London: Routledge.
- Avalos, M., Hellard, P. & Chatard, J. C. (2003). Modeling the training-performance relationship using a mixed model in elite swimmers. *Med Sci Sports Exerc*, 35 (5), 838–846.
- Backhaus, K., Erichson, B., Plinke, W. & Weiber, R. (2006). *Multivariate Analysemethoden. Eine anwendungsorientierte Einführung* (11. Aufl.). Berlin: Springer.
- Baechle, T. R. & Earle, R. (2008). *Essentials of Strength Training and Conditioning* (3. Auflage Aufl.). Champaign, IL: Human Kinetics.
- Ballreich, R. (1988). Grundlagen der Modellmethode. In R. Ballreich & W. Baumann (Hrsg.), *Grundlagen der Biomechanik des Sports* (S. 108–136). Stuttgart: Enke.
- Ballreich, R. & Kuhlow, A. (1975). Trainingswissenschaft - Darstellung und Begründung einer Forschungs- und Lehrkonzeption. *Leistungssport*, 5 (5), 95–103.
- Banister, E. W. (1991). Modeling Athletic Performance. In J. D. MacDougall, H. W. Wenger & H. J. Green (Hrsg.), *Physiological Testing of Elite Athletes* (S. 403–425). Champaign, IL: Human Kinetics.
- Banister, E. W. & Calvert, T. W. (1980). Planning for future performance: implications for long term training. *Can J Appl Sport Sci*, 5 (3), 170-6.
- Banister, E. W., Calvert, T. W., Savage, M. V. & Bach, T. M. (1975). A systems model of training for athletic performance. *Australian Journal of Sports Medicine*, 7 (3), 57–61.
- Banister, E. W., Carter, J. B. & Zarkadas, P. C. (1999). Training theory and taper: validation in triathlon athletes. *Eur J Appl Physiol Occup Physiol*, 79 (2), 182–191.
- Banister, E. W. & Hamilton, C. L. (1985). Variations in iron status with fatigue modelled from training in female distance runners. *Eur J Appl Physiol Occup Physiol*, 54 (1), 16–23.
- Birklbauer, J. (2005). *Modelle der Motorik*. Aachen: Meyer & Meyer Verlag.
- Bortz, J. & Weber, R. (2005). *Statistik für Human- und Sozialwissenschaftler* (6. Aufl.). Berlin: Springer.
- Brack, R. (2002). *Sportspielspezifische trainingslehre. Wissenschafts- und objekttheoretische Grundlagen am Beispiel Handball*. Hamburg: Czwalina.
- Bruce, R. A., Kusumi, F. & Hosmer, D. (1973). Maximal oxygen intake and nomographic assessment of functional aerobic impairment in cardiovascular disease. *Am Heart J*, 85 (4), 546-62.
- Brückner, J. P. & Wilhelm, A. (2008). Modellierung von individuellen Anpassungsprozessen. *Leistungssport*, 38 (2), 21–26.
- Bügner, J. (2005). *Nichtlineare Methoden in der trainingswissenschaftlichen Diagnostik*. Unveröffentlichte Dissertation, Universität Potsdam.

- Busso, T. (2003). Variable dose-response relationship between exercise training and performance. *Med Sci Sports Exerc*, 35 (7), 1188-95.
- Busso, T., Benoit, H., Bonnefoy, R., Feasson, L. & Lacour, J. R. (2002). Effects of training frequency on the dynamics of performance response to a single training bout. *J Appl Physiol*, 92 (2), 572–580.
- Busso, T., Candau, R. & Lacour, J. R. (1994). Fatigue and fitness modelled from the effects of training on performance. *Eur J Appl Physiol Occup Physiol*, 69 (1), 50–54.
- Busso, T., Carasso, C. & Lacour, J. R. (1991). Adequacy of a systems structure in the modeling of training effects on performance. *J Appl Physiol*, 71 (5), 2044-9.
- Busso, T., Denis, C., Bonnefoy, R., Geysant, A. & Lacour, J. R. (1997). Modeling of adaptations to physical training by using a recursive least squares algorithm. *J Appl Physiol*, 82 (5), 1685–1693.
- Busso, T., Häkkinen, K., Pakarinen, A., Carasso, C., Lacour, J. R., Komi, P. V. et al. (1990). A systems model of training responses and its relationship to hormonal responses in elite weightlifters. *Eur J Appl Physiol Occup Physiol*, 61 (1-2), 48–54.
- Busso, T., Häkkinen, K., Pakarinen, A., Kauhanen, H., Komi, P. V. & Lacour, J. R. (1992). Hormonal adaptations and modelled responses in elite weightlifters during 6 weeks of training. *Eur J Appl Physiol Occup Physiol*, 64 (4), 381–386.
- Busso, T. & Thomas, L. (2006). Using mathematical modeling in training planning. *Int J Sports Physiol Perform*, 1 (4), 400-5.
- Calvert, T. W., Banister, E. W., Savage, M. V. & Bach, T. M. (1976). A systems model of the effects of training on physical performance. *IEEE Trans Syst Man Cybernet*, 6 (2), 94–102.
- Candau, R., Busso, T. & Lacour, J. R. (1992). Effects of training on iron status in cross-country skiers. *Eur J Appl Physiol Occup Physiol*, 64 (6), 497–502.
- Carl, K. (1983). *Training und Trainingslehre in Deutschland*. Schorndorf: Hofmann.
- Dal Monte, A. (1974). *Analysis of physical capacity in sport and methods of functional evaluation*. Int. Symposium Sportmed., Teheran.
- DGSP. (2002a). *S1 - Leitlinie Vorsorgeuntersuchung im Sport*. Frankfurt am Main: Deutsche Gesellschaft für Sportmedizin und Prävention.
- DGSP. (2002b). *Leitlinien zur Belastungsuntersuchung in der Sportmedizin*. Frankfurt am Main: Deutsche Gesellschaft für Sportmedizin und Prävention.
- Dörner, D., Kreuzig, H. W., Reither, F. & Stäudel, T. (Hrsg.). (1983). *Lohhausen. Vom Umgang mit Unbestimmtheit und Komplexität*. Bern: Verlag Hans Huber.
- DTU. (2003). *Nachwuchstrainingskonzeption der Deutschen Triathlon Union*. Frankfurt am Main: Deutsche Triathlon Union.
- Edelmann-Nusser, J. (2005). *Sport und Technik. Anwendung moderner Technologien in der Sportwissenschaft*. Aachen: Shaker.
- Edelmann-Nusser, J., Hohmann, A., Bügner, J. & Witte, K. (2009). Modeling Performance Upon Neural Networks. In A. Hökelmann, K. Witte & P. O'Donoghue (Hrsg.), *Current Trends in*

- Performance Analysis: World Congress of Performance Analysis of Sport VIII* (S. 349–357). Aachen: Shaker.
- Edelmann-Nusser, J., Hohmann, A. & Henneberg, B. (2001). Prognose der Olympischen Wettkampfleistung im Schwimmen. *Leistungssport*, 31 (3), 20–23.
- Edelmann-Nusser, J., Hohmann, A. & Henneberg, B. (2006). Modellierung von Wettkampfleistungen im Schwimmen bei den Olympischen Spielen 2000 und 2004 mittels Neuronaler Netze. *Leistungssport*, 36 (2), 45–50.
- Eisenbach, D. (2005). *Künstliche neuronale Netze zur Prognose von Zeitreihen*. Diplomarbeit, Westfälische Wilhelms-Universität Münster.
- Ferger, K. (1998). *Trainingseffekte im fußball*. Hamburg: Czwalina.
- Fitz-Clarke, J. R., Morton, R. H. & Banister, E. W. (1991). Optimizing athletic performance by influence curves. *J Appl Physiol*, 71 (3), 1151-8.
- Foerster, H. v. (1988). Abbau und Aufbau. In F. B. Simon (Hrsg.), *Lebende Systeme* (S. 19–33). Berlin: Springer.
- Fröhlich, M., Klein, M., Pieter, A. & Emrich, E. (2008). Ökonomische Betrachtung zur Wettkampfstruktur im Olympischen Triathlon - ein explorativer Ansatz. *Leistungssport*, 5 (38), 42–46.
- Ganter, N. (2009). *Adaptationsverhalten im Trainingsprozess - Modellierung des Verlaufs der sportlichen Leistungsfähigkeit unter besonderer Berücksichtigung des Frequenzverhaltens von Oberflächen-EMG-signalen im Schwimmen und Radfahren*. Unveröffentlichte Dissertation, Universität Magdeburg.
- Ganter, N., Witte, K. & Edelmann-Nusser, J. (2006). Einsatz von antagonistischen Trainings-Wirkungs-Modellen zur LeistungspräDiktion im Radfahren. In J. Edelmann-Nusser & K. Witte (Hrsg.), *Sport und informatik ix* (S. 43–48). Aachen: Shaker.
- Ganter, N., Witte, K., Giggel, S. & Edelmann-Nusser, J. (2008). Trainingswirkungsanalyse im Olympischen Bogenschießen. In M. Lames, C. Augste, O. Cordes, C. Dreckmann, K. Görsdorf & M. Siegle (Hrsg.), *Gegenstand und Anwendungsfelder der Sportinformatik* (S. 102–107). Hamburg: Czwalina.
- Gerok, W. (1990). Ordnung und Chaos als Elemente von Gesundheit und Krankheit. In W. Gerok (Hrsg.), *Ordnung und Chaos in der unbelebten und belebten Natur* (S. 19–41). Stuttgart: Hirzel.
- Glitsch, U. (2002). Naturwissenschaftliche Modellbildung in der Sportwissenschaft. In J. Perl, M. Lames & U. Glitsch (Hrsg.), *Modellbildung in der Sportwissenschaft* (S. 99-178). Schorndorf: Hofmann.
- Goodband, J. H., Haas, O. C. L. & Mills, J. A. (2008). A comparison of neural network approaches for on-line prediction in igrt. *Med Phys*, 35 (3), 1113-22.
- Green, H. J., Hughson, R. L., Orr, G. W. & Ranney, D. A. (1983). Anaerobic threshold, blood lactate, and muscle metabolites in progressive exercise. *J Appl Physiol*, 54 (4), 1032-8.
- Haken, H. (1995). *Erfolgsgeheimnisse der Natur. Synergetik: Die Lehre vom Zusammenwirken*. Reinbek: Rowohlt.



- Haken, H. (1996). Chaos und Ordnung: Zur Selbstorganisation komplexer Systeme in Physik, Biologie und Soziologie. In J. P. Janssen, K. Carl, W. Schlicht & A. Wilhelm (Hrsg.), *Synergetik und Systeme im Sport* (S. 23–52). Schorndorf: Hofmann.
- Haken, H. (2004). *Die Selbstorganisation Komplexer Systeme - Ergebnisse aus der Werkstatt der Chaostheorie*. Wien: Picus.
- Haken, H., Kelso, J. A. & Bunz, H. (1985). A theoretical model of phase transitions in human hand movements. *Biol Cybern*, 51 (5), 347-56.
- Hansmann, K. W. (1983). *Kurzlehrbuch Prognoseverfahren*. Wiesbaden: Gabler.
- Hellard, P., Avalos, M., Lacoste, L., Barale, F., Chatard, J. C. & Millet, G. P. (2006). Assessing the limitations of the banister model in monitoring training. *J Sports Sci*, 24 (5), 509–520.
- Hickson, R. C., Hagberg, J. M., Ehsani, A. A. & Holloszy, J. O. (1981). Time course of the adaptive responses of aerobic power and heart rate to training. *Med Sci Sports Exerc*, 13 (1), 17-20.
- Hickson, R. C., Rosenkoetter, M. A. & Brown, M. M. (1980). Strength training effects on aerobic power and short-term endurance. *Med Sci Sports Exerc*, 12 (5), 336-9.
- Hippert, H. S., Pedreira, C. E. & Souza, R. C. (2001). Neural networks for short-term load forecasting: A review and evaluation. *IEEE Transactions on Power Systems*, 16, 44–55.
- Hoffmann, J. (1993). *Vorhersage und Erkenntnis*. Göttingen: Hogrefe.
- Hohmann, A. (1986). Trainingswissenschaftliche Analyse eines einjährigen Trainingsprozesses im Sportspiel Wasserball. *Leistungssport*, 16 (5), 5–10.
- Hohmann, A. (1994). *Grundlagen der Trainingssteuerung im Sportspiel*. Hamburg: Czwalina.
- Hohmann, A. (2005). Steuerung sportlicher Spitzenleistungen aus trainingswissenschaftlicher Perspektive. *Leistungssport*, 35 (6), 56–62.
- Hohmann, A., Bügner, J., Kellmann, M., Edelmann-Nusser, J. & Döbler, S. (2001). Non-linear identification of different states of performance as order parameters in an athletic process. In J. Mester, G. King, H. Strüder, E. Tsolakidis & A. Osterburg (Hrsg.), *Perpectives and Profiles. 15th Congress of the German Society of Sport Science* (S. 332). Köln: Sport und Buch Strauss.
- Hohmann, A., Edelmann-Nusser, J. & Henneberg, B. (2000). A nonlinear approach to the analysis and modeling of training and adaptation in swimming. In *Application of Biomechanical Study in swimming. Proceedings of XVIII International Symposium on Biomechanics in Sports* (S. 31–38). Hong Kong: Chinese University Press.
- Hohmann, A., Lames, M. & Letzelter, M. (2007). *Einführung in die Trainingswissenschaft* (4. Aufl.). Wiebelsheim: Limpert.
- Hollmann, W. & Strüder, H. K. (2009). *Sportmedizin. Grundlagen für körperliche Aktivität, Trainings- und Präventivmedizin* (5. Aufl.). Stuttgart: Schattauer.
- Hottenrott, K. (2010). Ist das Superkompensationsmodell noch aktuell? *Leistungssport*, 35 (2), 13–19.
- Hu, M. J. C. (1964). *Application of adaline system to weather forecasting*. Unveröffentlichte Diplomarbeit, Stanford Electronic Laboratories, Stanford, CA.
- Jakowlew, N. N. (1977). *Sportbiochemie*. Leipzig: Barth.

- Janssen, J. P., Carl, K., Schlicht, W. & Wilhelm, A. (Hrsg.). (1996). *Synergetik und Systeme im Sport*. Schorndorf: Hofmann.
- Kallus, K. W. & Kellmann, M. (2000). Burnout in athletes and coaches. In Y. L. Hanin (Hrsg.), *Emotions in Sport* (S. 209–230). Champaign, IL: Human Kinetics.
- Kandel, E. R., Schwartz, J. H. & Jessell, T. M. (Hrsg.). (2000). *Principles of Neural Science* (4. Auflage Aufl.). NewYork: McGraw-Hill.
- Kellmann, M. (2002). Underrecovery and overtraining: Different concepts - similar impact? In M. Kellmann (Hrsg.), *Enhancing recovery: Preventing underperformance in athletes* (S. 3–24). Champaign, IL: Human Kinetics.
- Kellmann, M. & Kallus, K. W. (2000). Der Erholungs-Belastungs-Fragebogen für Sportler [Software-Handbuch]. Frankfurt: Verlag Swets Test service.
- Kenttä, G. & Hassmen, P. (1998). Overtraining and Recovery. *Sports Med*, 26 (1), 1–16.
- Kroidl, R. F., Schwarz, S. & Lehnigk, B. (2007). *Kursbuch Spiroergometrie*. Stuttgart: Georg Thieme Verlag.
- Kruse, H., Mangold, R., Mechler, B. & Penger, O. (1991). *Programmierung Neuronaler Netze. Eine Turbo Pascal Toolbox*. Bonn: Addison-Wesley.
- Lames, M. (1991). *Leistungsdiagnostik durch Computersimulation. Ein Beitrag zur Theorie der Sportspiele am Beispiel Tennis*. Frankfurt am Main: Deutsch.
- Lames, M. (1994). *Systematische Spielbeobachtung*. Münster: Philippka.
- Lames, M. (1996). Zeitreihenanalysen: Anwendungen in der Trainingswissenschaft. In K. J (Hrsg.), *Zeitreihenanalysen und multiple statistische Verfahren in der Trainingswissenschaft* (S. 45–57). Köln: Sport und Buch Strauss.
- Lames, M. (1999). Evaluationsforschung in der Trainingswissenschaft. In A. Hohmann, E. Wichmann & K. Carl (Hrsg.), *Feldforschung in der Trainingswissenschaft* (S. 49–64). Köln: Strauß.
- Lames, M. (2002). Verhaltenswissenschaftliche Modellbildung in der Sportwissenschaft. In J. Perl, M. Lames & U. Glitsch (Hrsg.), *Modellbildung in der Sportwissenschaft* (S. 179–253). Schorndorf: Hofmann.
- Lämmel, U. & Cleve, J. (2004). *Künstliche Intelligenz* (2. Aufl.). Leipzig: Fachbuchverlag.
- Lapedes, A. & Farber, R. (1987). *Nonlinear signal processing using neural networks: prediction and system modeling* (Bericht). Technical Report LA-UR-87-2662, Los Alamos National Laboratory, Los Alamos, NM.
- Le Bris, S., Ledermann, B., Candau, R., Davy, J. M., Messner-Pellenc, P. & Le Gallais, D. (2004). Applying a systems model of training to a patient with coronary artery disease. *Med Sci Sports Exerc*, 36 (6), 942-8.
- Le Bris, S., Ledermann, B., Topin, N., Messner-Pellenc, P. & Le Gallais, D. (2006). A systems model of training for patients in phase 2 cardiac rehabilitation. *Int J Cardiol*, 109 (2), 257-63.
- Letzelter, M. (1978). *Trainingsgrundlagen*. Reinbek: Rowohlt.
- Maas, S., Liesen, H., Mester, J. & Neumaier, A. (1995). Einzelfallanalyse als Mittel individueller

- Trainingssteuerung. In J. Krug & H. J. Minow (Hrsg.), *Sportliche Leistung und Training* (S. 321–326).
- Mainzer, K. (2008). *Komplexität*. Stuttgart: UTB.
- Manis, G., Nikolopoulos, S., Alexandridi, A. & Davos, C. (2007, May). Assessment of the classification capability of prediction and approximation methods for hrv analysis. *Comput Biol Med*, 37 (5), 642-54.
- Martin, D., Carl, K. & Lehnertz, K. (1991). *Handbuch Trainingslehre*. Schorndorf: Hofmann.
- McCulloch, W. S. & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5, 115–133.
- McNair, D., Lorr, M., Droppleman, L. F., Biehl, B. & Dangel, S. (1981). Profile of Mood States (Dt. bearbeitung), in Kollegium Internationale Psychiatrie Scalarum [Software-Handbuch]. Weinheim: Beltz Verlag.
- Meeusen, R., Duclos, M., Gleeson, M., Rietjens, G., Steinacker, J. & Urhausen, A. (2006). Prevention, diagnosis and treatment of the overtraining syndrome. *European Journal of Sport Science*, 6 (1), 1–14.
- Mester, J. & Maas, S. (1996). Methodenverständnis und Methodensystem in der Trainingswissenschaft. In H. A. Thorhauer, K. Carl & U. Türck-Noack (Hrsg.), *Trainingswissenschaft: Theoretische und methodische Fragen in der Diskussion* (S. 75–90).
- Mester, J. & Perl, J. (2000). Grenzen der Anpassungs- und Leistungsfähigkeit des Menschen aus systemischer Sicht. *Leistungssport*, 30 (1), 43 – 51.
- Meyer, T., Lucía, A., Earnest, C. P. & Kindermann, W. (2005). A conceptual framework for performance diagnosis and training prescription from submaximal gas exchange parameters–theory and application. *Int J Sports Med*, 26 Suppl 1, S38-48.
- Millet, G. P., Candau, R. B., Barbier, B., Busso, T., Rouillon, J. D. & Chatard, J. C. (2002). Modelling the transfers of training effects on performance in elite triathletes. *Int J Sports Med*, 23 (1), 55–63.
- Morton, R. H., Fitz-Clarke, J. R. & Banister, E. W. (1990). Modeling human performance in running. *J Appl Physiol*, 69 (3), 1171-7.
- Moshiri, S. & Cameron, N. (2000). Neural network versus econometric models in forecasting inflation. *Journal of Forecasting*, 19 (3), 201–217.
- Mujika, I., Busso, T., Geysant, A., Chatard, J. C., Lacoste, L. & Barale, F. (1996). Modeling the effects of training in competitive swimming. In J. P. Troup, A. P. Hollander, D. Strasse, S. W. Trappe, J. M. Cappaert & T. A. Trappe (Hrsg.), *Biomechanics and Medicine in Swimming VII* (S. 221–228). London: E F Spon.
- Mujika, I., Chatard, J. C., Busso, T., Geysant, A., Barale, F. & Lacoste, L. (1995). Effects of training on performance in competitive swimming. *Can J Appl Physiol*, 20 (4), 395–406.
- Osterburg, A. (2004). *Einzelfall-zeitreihenanalyse im Langdistanz-Triathlon: Reaktion und Adaptation physiologischer Parameter in Folge sehr hoher Trainingsbelastungen*. Unveröffentlichte Dissertation, Deutsche Sporthochschule Köln.

- Panerai, R. B., Chacon, M., Pereira, R. & Evans, D. H. (2004). Neural network modelling of dynamic cerebral autoregulation: assessment and comparison with established methods. *Med Eng Phys*, 26 (1), 43-52.
- Perl, J., Lames, M. & Glitsch, U. (Hrsg.). (2002). *Modellbildung in der Sportwissenschaft*. Schorndorf: Hofmann.
- Perl, J., Lames, M. & Miethling, W. D. (Hrsg.). (1997). *Informatik im Sport. Ein Handbuch*. Schorndorf: Hofmann.
- Perl, J. & Mester, J. (2001). Modellgestützte und statistische Analyse der Wechselwirkung zwischen Belastung und Leistung. *Leistungssport*, 31 (2), 54–62.
- Perl, J. & Uthmann, T. (1997). Modellbildung. In J. Perl, M. Lames & W. D. Miethling (Hrsg.), *Informatik im Sport. Ein Handbuch* (S. 43–64). Schorndorf: Hofmann.
- Petermann, F. (Hrsg.). (1996). *Einzelfallanalyse* (3. Aufl.). München: Oldenbourg.
- Petrosian, A., Prokhorov, D., Homan, R., Dasheiff, R. & Wunsch, D. (2000). Recurrent neural network based prediction of epileptic seizures in intra- and extracranial EEG. *Neurocomputing*, 30, 201–208.
- Petrović, J., Ibrić, S., Betz, G., Parojčić, J. & Durić, Z. (2009). Application of dynamic neural networks in the modeling of drug release from polyethylene oxide matrix tablets. *Eur J Pharm Sci*, 38 (2), 172-80.
- Pfeiffer, M. & Perl, J. (2009). Simulative Trainingswirkungsanalyse bei einem Fahrradergometrie-training mittels antagonistischer Modelle. In M. Lames, C. Augste, O. Cordes, C. Dreckmann, K. Görsdorf & M. Siegle (Hrsg.), *Gegenstand und Anwendungsfelder der Sportinformatik* (S. 41–51). Hamburg: Czwalina.
- Popper, K. (1971). *Logik der Forschung*. Tübingen: Mohr.
- Revenstorf, D. & Keeser, W. (1996). Zeitreihenanalyse von Therapieverläufen - ein Überblick. In F. Petermann (Hrsg.), *Einzelfallanalyse* (S. 167–212). München: Oldenbourg.
- Rey, G. D. & Wender, K. F. (2008). *Neuronale Netze. Eine EinüEhrung in Grundlagen, Anwendungen und Datenauswertung*. Bern: Verlag Hans Huber.
- Richardson, S. O., Andersen, M. B. & Morris, T. (2008). *Overtraining Athletes*. Champaign: Human Kinetics.
- Ritter, H., Martinetz, T. & Schulten, K. (1991). *Neuronale Netze. Eine EinüEhrung in die Neuroinformatik selbstorganisierender Netzwerke* (2. Aufl.). Bonn: Addison-Wesley.
- Rohmert, W. & Rutenfranz, J. (1975). *Arbeitswissenschaftliche Beurteilung des Belastung und Beanspruchung an unterschiedlichen industriellen Arbeitsplätzen*. Bonn: Bundesminister für Arbeit und Soziales.
- Rojas, R. (1996). *Theorie der neuronalen netze. Eine systematische Einführung*. Berlin: Springer.
- Rosenblatt, F. (1958, Nov). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychol Rev*, 65 (6), 386-408.
- Rossi, P. H. & Freeman, H. E. (1993). *Evaluation: A systematic approach* (4. Aufl.). Beverly Hills, CA: Sage.

- Rumelhart, D. E., E, H. G. & Williams, R. J. (1986). Learning representations by backpropagating errors. *Nature*, 323 (3088), 533–536.
- Sands, W. A. & McNeal, J. R. (2000). Predicting Athlete Preparation and Performance: A Theoretical Perspective. *Journal of Sport Behavior*, 23 (3), 289–310.
- Sawka, M.N. & Young, A.J. (2000). Exercise in hot and cold climates. In W.E. Garrett & D.T. Kirkendall (Hrsg.), *Exercise and Sport Science* (S. 385–400). Philadelphia: Williams and Wilkins.
- Schabort, E. J., Killian, S. C., St Clair Gibson, A., Hawley, J. A. & Noakes, T. D. (2000). Prediction of triathlon race time from laboratory testing in national triathletes. *Med Sci Sports Exerc*, 32 (4), 844-9.
- Schlicht, W. (1988). *Einzelfallanalysen im Hochleistungssport*. Schorndorf: Hofmann.
- Schlicht, W. (1992). Das sportliche Training: Überlegungen auf dem Wege zu einem integrierten Belastungs-Beanspruchungs-Konzept. In J. P. Janssen, W. Schlicht, H. Rieckert & K. Carl (Hrsg.), *Belastung und Beanspruchung* (S. 31–44). Köln: Strauß.
- Schlicht, W. & Janssen, J. P. (1990). Der Einzelfall in der empirischen Forschung der Sportwissenschaft: Begründung und Demonstration zeitreihen-analytischer Methoden. *Sportwissenschaft*, 20 (3), 263–280.
- Schlicht, W. & Lames, M. (1993). Wissenschaft und Technologie: Ideen zu einer Forschungskonzeption in der Trainingswissenschaft. In D. Martin & T. Weigelt (Hrsg.), *Trainingswissenschaft. Selbstwertsändnis und Forschungsansätze* (S. 78–94). St. Augustin: Academica.
- Schlittgen, R. & Streitberg, B. H. J. (2001). *Zeitreihenanalyse* (Bd. 9. Auflage). München: Oldenbourg.
- Schmidt, H. (2005). *Modelle, komplexe Systeme und Möglichkeiten von Zeitreihenanalysen zur sportlichen Leistungsoptimierung - theoretische und empirische Untersuchungen*. Unveröffentlichte Dissertation, Universität Dortmund.
- Schmitz, B. (1989). *Einführung in die Zeitreihenanalyse. Modelle, Softwarebeschreibung, Anwendungen*. Bern: Verlag Hans Huber.
- Schnabel, G., Harre, D. & Krug, J. (2005). *Trainingswissenschaft. Leistung. Training. Wettkampf*. München: Südwest Verlag.
- Sharda, R. & Patil, R. B. (1992). Connectionist approach to time series prediction: An empirical test. *Journal of Intelligent Manufacturing*, 3 (5), 317–323.
- Shieh, J. S., Chou, C. F., Huang, S. J. & Kao, M. C. (2004). Intracranial pressure model in intensive care unit using a simple recurrent neural network through time. *Neurocomputing*, 57, 239 - 256. (New Aspects in Neurocomputing: 10th European Symposium on Artificial Neural Networks 2002)
- Sleivert, G. G. & Rowlands, D. S. (1996, Jul). Physical and physiological factors associated with success in the triathlon. *Sports Med*, 22 (1), 8-18.
- Stachowiak, H. (1973). *Allgemeine Modelltheorie*. Wien: Springer.
- Stark, G. (1984). Sporttechnisches Training und zwei Grundlegende Prinzipien der Leistungsentwicklung. *Theorie und Praxis Leistungssport*, 22 (12), 3–12.

- Taha, T. & Thomas, S. G. (2003). Systems modelling of the relationship between training and performance. *Sports Med*, 33 (14), 1061–1073.
- Tanaka, H. (1994, Nov). Effects of cross-training. transfer of training effects on VO<sub>2</sub>max between cycling, running and swimming. *Sports Med*, 18 (5), 330-9.
- Thiesing, F. M. (1998). *Analyse und Prognose von Zeitreihen mit Neuronen Netzen*. Aachen: Shaker.
- Torrents, C., Balagué, N., Perl, J. & Schöllhorn, W. (2007). Linear and non-linear analysis of the traditional and differential strength training. *Ugdymas. Kuno Kultura. Sportas*, 66 (3), 39–47.
- Tschopp, M. (2001). *Leistungsdiagnostik Ausdauer*. Magglingen.
- Van Schuylenbergh, R., Eynde, B. V. & Hespel, P. (2004). Prediction of sprint triathlon performance from laboratory tests. *Eur J Appl Physiol*, 91 (1), 94-9.
- Wilmore, J. H., Costill, D. L. & Kenney, W. L. (2008). *Physiology of Sport and Exercise* (4. Aufl.). Champaign, IL: Human Kinetics.
- Witte, K. (2002). *Stabilitäts- und Variabilitätserscheinungen der Motorik des Sportlers unter nichtlinearem Aspekt*. Aachen: Shaker.
- Wood, R. E., Hayter, S., Rowbottom, D. & Stewart, I. (2005). Applying a mathematical model to training adaptation in a distance runner. *Eur J Appl Physiol*, 94 (3), 310-6.
- Yang, Z., Yang, Z., Lu, W., Harrison, R. G., Eftestøl, T. & Steen, P. A. (2005, Jan). A probabilistic neural network as the predictive classifier of out-of-hospital defibrillation outcomes. *Resuscitation*, 64 (1), 31-6.
- Zaciorskij, V. M. (1971). Kybernetik - Mathematik - Sport. *Theorie und Praxis der Körperkultur* (12), 1068–1091.
- Zaciorskij, V. M. (1972). Kybernetik - Mathematik - Sport. *Theorie und Praxis der Körperkultur*, 1-5, 50-67; 133-149; 224-234; 325-336; 458-472.
- Zell, A. (1997). *Simulation Neuronaler Netze*. Bonn: Addison-Wesley.
- Zell, A. e. a. (1998). Snns - Stuttgarter Neuronale Netzwerk simulator [Software-Handbuch].
- Zhang, G., Patuwo, B. E. & Hu, M. Y. (1998). Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*, 14, 35–62.

# Anhang A

## Erholungs-Belastungs-Fragebogen (EBF-Sport)

Tabelle A.1: EBF-Sport

Frage	In den letzten 3 Tagen und Nächten
1	... habe ich ferngesehen
2	... hatte ich zuwenig Schlaf
3	... habe ich wichtige Arbeiten abgeschlossen
4	... war ich unkonzentriert
5	... war ich gereizt
6	... habe ich gelacht
7	... hatte ich körperliche Beschwerden
8	... war ich mißgestimmt
9	... habe ich mich körperlich entspannt gefühlt
10	... war ich guter Dinge
11	... konnte ich mich schlecht konzentrieren
12	... habe ich Konflikte mit mir herumgetragen
13	... fühlte ich mich ausgeglichen
14	... habe ich mit Freunden schöne Stunden verbracht
15	... hatte ich Kopfdruck oder Kopfschmerzen
16	... hat mich die Arbeit stark ermüdet
17	... hatte ich Erfolg
18	... gingen mir die gleichen Gedanken immer wieder durch den Kopf
19	... bin ich zufrieden und entspannt eingeschlafen
20	... habe ich mich körperlich unwohl gefühlt
21	... habe ich mich über andere geärgert
22	... fühlte ich mich niedergeschlagen

**Tabelle A.1:** EBF-Sport

<b>Frage</b>	<b>In den letzten 3 Tagen und Nächten</b>
23	... habe ich Freunde getroffen
24	... war ich betrübt
25	... war ich nach meiner Arbeit todmüde
26	... sind mir andere „auf die Nerven gegangen“
27	... war mein Schlaf erholsam
28	... litt ich unter Ängsten oder Hemmungen
29	... fühlte ich mich körperlich fit
30	... hatte ich die „Nase voll“
31	... konnte ich meine Arbeit nur schleppend erledigen
32	... habe ich mich vor Fremden bewähren müssen
33	... habe ich mich amüsiert
34	... hatte ich gute Laune
35	... war ich übermüdet
36	... habe ich unruhig geschlafen
37	... habe ich mich geärgert
38	... fühlte ich mich leistungsfähig
39	... war ich aufgebracht
40	... habe ich Arbeiten vor mir hergeschoben
41	... habe ich wichtige Entscheidungen getroffen
42	... fühlte ich mich körperlich matt
43	... war ich glücklich
44	... stand ich unter Leistungsdruck
45	... wurde mir alles zuviel
46	... bin ich nachts ohne äußeren Anlass aufgewacht
47	... war ich zufrieden
48	... war ich böse auf andere
49	... hatte ich gute Ideen
50	... taten mir Teile meines Körpers weh
51	... bin ich in den Pausen nicht zur Ruhe gekommen
52	... war ich überzeugt, dass ich das gesteckte Ziel gut erreichen könnte
53	... konnte ich mich körperlich gut erholen
54	... fühlte ich mich durch meinen Sport ausgebrannt
55	... habe ich in meinem Sport viel Lohnendes erreicht
56	... konnte ich mich mental auf meine sportlichen Leistungen vorbereiten



**Tabelle A.1:** EBF-Sport

<b>Frage</b>	<b>In den letzten 3 Tagen und Nächten</b>
57	... litt ich während meiner sportlichen Leistungen unter Muskelverhärtungen oder -verspannungen
58	... hatte ich den Eindruck, zu wenige Pausen zu haben
59	... war ich überzeugt, dass ich meine Leistungsziele jederzeit erreichen könnte
60	... konnte ich mich effektiv um die Probleme in meinem Team kümmern
61	... war ich körperlich in guter Verfassung
62	... konnte ich mich während meiner sportlichen Leistungen selbst antreiben
63	... fühlte ich mich durch meinen Sport gefühlsmäßig ausgelaugt
64	... hatte ich nach meinen sportlichen Leistungen Muskelschmerzen
65	... war ich überzeugt, dass ich optimal vorbereitet bin
66	... wurde ich in den Pausen zu stark beansprucht
67	... konnte ich mich vor meinen sportlichen Leistungen voll motivieren
68	... war mir danach, mit dem Sport aufzuhören
69	... fühlte ich mich energiegeladen
70	... konnte ich gut nachvollziehen was in meinem Team vorging
71	... war ich überzeugt, gut trainiert zu haben
72	... waren die Pausen an der falschen Stelle
73	... war ich empfindlich gegenüber Verletzungen
74	... habe ich mir für meine sportlichen Leistungen klare Ziele gesetzt
75	... war ich körperlich entspannt
76	... hat mich mein Sport frustriert
77	... konnte ich mit gefühlsmäßigen Problemen in meinem Team gut umgehen

**Tabelle A.2:** Auswertung EBF-Sport

<b>Subtest / Itemzahl</b>	<b>Bezeichnung</b>	<b>Frage</b>
1 (k=4)	Allgemeine Beanspruchung - Niedergeschlagenheit	22, 24, 30, 45
2 (k=4)	Emotionale Beanspruchung	5, 8, 28, 37
3 (k=4)	Soziale Beanspruchung	21, 26, 39, 48
4 (k=4)	Ungelöste Konflikte - Leistungsdruck	12, 18, 32, 44
5 (k=4)	Übermüdung - Zeitdruck	2, 16, 25, 35
6 (k=4)	Energielosigkeit - Unkonzentriertheit	4, 11, 31, 40
7 (k=4)	Somatische Beanspruchung	7, 15, 20, 42
8 (k=4)	Erfolg - Leistungsfähigkeit	3, 17, 41, 49
9 (k=4)	Soziale Erholung	6, 14, 23, 33
10 (k=4)	Somatische Erholung	9, 13, 29, 38
11 (k=4)	Allgemeine Erholung - Wohlbefinden	10, 34, 43, 47
12 (k=4)	Erholsamer Schlaf	19, 27, 36 (invertiert), 46 (invertiert)
13 (k=4)	Gestörte Pause	51, 58, 66, 72
14 (k=4)	Burnout / Emotionale Erschöpfung	54, 63, 68, 76
15 (k=4)	Fitneß / Verletzungsanfälligkeit	50, 57, 64, 73
16 (k=4)	Fitneß / In Form sein	53, 61, 69, 75
17 (k=4)	Burnout / Persönliche Verwirklichung	55, 60, 70, 77
18 (k=4)	Selbstwirksamkeitsüberzeugung	52, 59, 65, 71
19 (k=4)	Selbstregulation	56, 62, 67, 74
<b>Bereichssubtest</b>	<b>Beschreibung</b>	<b>Subtests</b>
1 (k=7)	Beanspruchung	1 - 7
2 (k=5)	Erholung	8 - 12
3 (k=3)	sportartspezifische Belastung	13 - 15
4 (k=4)	sportartspezifische Erholung	16 - 19
<b>Globalwert</b>	<b>Beschreibung</b>	<b>Bereichssubtest</b>
1	Gesamtbeanspruchungswert (GBW)	1 und 3
2	Gesamterholungswert (GEW)	2 und 4

# Anhang B

## Wertetabellen

Tabelle B.1: Datentabelle Proband P1

Messzeitpkt.	Masse [kg]	Ruhe-HF	Rad- TRIMP	Laufen- TRIMP	Schwimmen- TRIMP	Kraft- TRIMP	Gesamt- TRIMP	VO <sub>2</sub> max [l·min <sup>-1</sup> ]	rel. VO <sub>2</sub> max [ml·min <sup>-1</sup> ·kg <sup>-1</sup> ]	GBW	GEW
1	76,5	55	0	0	0	0	0	3,56	3,8	1,6	3,6
2	76,6	57	70	370	23	0	463	3,70	3,8	1,8	3,5
3	76,3	54	30	72	0	0	102	3,50	3,8	1,4	3,3
4	76,2	56	121	0	236	0	357	3,64	3,8	1,4	3,8
5	76,1	57	33	0	322	0	355	3,63	3,9	1,9	3,5
6	76,3	56	32	93	307	0	432	3,59	3,9	1,6	3,2
7	76,1	56	30	0	114	0	144	3,64	3,7	1,7	2,7
8	76,6	56	29	78	0	0	107	3,81	3,9	1,3	3,0
9	76,5	54	89	224	0	0	313	3,65	3,9	1,2	3,2
10	76,4	53	207	61	171	0	438	3,45	3,8	1,2	3,5
11	76,3	60	29	95	271	0	395	3,78	3,8	1,1	3,8
12	76,4	55	34	157	252	62	505	3,54	3,8	1,5	3,7
13	76,3	56	152	0	0	45	197	3,70	3,9	1,4	3,7
14	76,2	53	32	255	167	0	454	3,59	3,8	1,4	4,1
15	76,4	58	31	257	0	0	288	3,67	3,8	1,5	3,5
16	76,3	66	28	197	0	0	225	3,52	3,7	1,7	3,5
17	76,4	66	259	86	266	0	610	3,56	3,7	2,2	3,7
18	76,4	51	25	0	18	0	43	3,57	3,8	1,5	2,4
19	76,1	56	30	41	315	0	386	3,52	3,8	1,5	3,2
20	76,2	53	27	125	0	28	181	3,44	3,8	1,3	3,1
21	76,3	58	102	239	82	27	449	3,40	3,8	2,0	2,8
22	76,3	52	29	191	126	0	346	3,39	3,6	1,9	3,1
23	76,4	60	95	67	140	0	302	3,34	3,7	1,7	2,2
24	76,1	60	25	0	132	0	158	3,22	3,8	1,7	2,5
25	76,3	58	29	156	89	0	275	3,55	3,8	1,9	2,8
26	76,3	56	160	149	290	0	599	3,57	3,8	1,5	3,4
27	76,5	58	82	0	0	0	82	3,48	3,7	1,7	1,3
28	76,3	52	26	0	0	0	26	3,50	3,8	1,6	2,3
29	76,3	56	32	394	40	0	466	3,49	3,6	1,7	3,1
30	76,3	59	95	49	0	0	144	3,50	3,6	1,7	2,5
<b>Mittelwert</b>	76,3	57	65	112	112	5	295	3,55	3,8	1,6	3,1
<b>Std.-Abw.</b>	0,1	4	61	112	119	15	171	0,13	0,1	0,3	0,6

Tabelle B.2: Datentabelle Proband P2

Messzeitpkt.	Masse [kg]	Ruhe-HF	Rad- TRIMP	Laufen- TRIMP	Schwimmen- TRIMP	Kraft- TRIMP	Gesamt- TRIMP	VO <sub>2</sub> max [l·min <sup>-1</sup> ]	rel. VO <sub>2</sub> max [ml·min <sup>-1</sup> ·kg <sup>-1</sup> ]	GBW	GEW
1	68,6	56	0	93	0	0	93	3,56	51,8	2,0	3,8
2	69,1	65	17	185	53	0	254	3,70	53,5	2,1	3,6
3	68,6	47	17	63	56	0	137	3,50	50,9	1,9	4,3
4	68,5	52	219	85	0	0	304	3,64	53,1	2,5	3,4
5	68,7	52	21	198	49	0	268	3,63	52,8	1,8	3,6
6	67,6	56	22	189	0	0	211	3,59	53,1	1,8	4,0
7	68,8	58	22	114	48	0	184	3,64	52,9	2,0	3,7
8	68,7	54	17	222	0	0	239	3,81	55,4	1,5	4,8
9	68,7	53	20	120	0	0	140	3,65	53,1	2,1	4,5
10	69,2	54	21	163	0	0	184	3,45	49,8	2,1	2,7
11	68,4	55	19	0	0	0	19	3,78	55,2	1,7	3,0
12	68,5	50	20	0	0	0	20	3,54	51,7	1,8	3,1
13	68,2	54	21	0	96	0	117	3,70	54,3	1,6	3,7
14	67,6	59	21	152	0	41	214	3,59	53,2	1,3	4,6
15	68,8	56	21	65	91	0	177	3,67	53,3	1,4	4,4
16	68,4	60	21	75	70	20	187	3,52	51,5	1,9	3,4
17	68,5	55	21	135	63	0	220	3,56	52,0	1,4	4,3
18	68	61	20	280	66	18	384	3,57	52,5	2,1	4,5
19	69,1	61	22	172	0	19	212	3,52	50,9	1,9	4,8
20	68,3	55	20	168	86	20	294	3,44	50,4	1,6	4,6
21	67,9	59	21	183	0	20	223	3,40	50,1	1,9	4,7
22	68,2	52	21	269	0	0	290	3,39	49,6	1,7	4,6
23	67,7	55	19	61	98	22	200	3,34	49,3	2,1	3,9
24	67,9	63	17	109	0	0	126	3,22	47,3	3,0	2,6
25	67,4	54	16	0	0	0	16	3,55	52,6	1,9	3,3
26	68,5	50	21	0	0	0	21	3,57	52,0	2,3	3,1
27	67,5	53	22	80	134	22	258	3,48	51,5	1,7	4,1
28	67,1	54	24	112	0	21	156	3,50	52,1	1,9	3,9
29	67,2	54	22	161	0	0	183	3,49	52,0	2,3	4,1
30	66,8	59	24	84	0	0	108	3,50	52,4	2,3	4,2
<b>Mittelwert</b>	68,2	56	26	118	30	7	181	3,55	52,0	1,9	3,9
<b>Std.-Abw.</b>	0,6	4	37	78	41	11	91	0,13	1,7	0,4	0,6

Tabelle B.3: Datentabelle Proband P3

Messzeitpkt.	Masse [kg]	Ruhe-HF	Rad- TRIMP	Laufen- TRIMP	Schwimmen- TRIMP	Kraft- TRIMP	Gesamt- TRIMP	VO <sub>2</sub> max [l·min <sup>-1</sup> ]	rel. VO <sub>2</sub> max [ml·min <sup>-1</sup> ·kg <sup>-1</sup> ]	GBW	GEW
1	67,1	67	580	90	0	0	671	4,00	3,8	2,1	3,5
2	67,4	53	19	105	0	0	124	3,93	3,8	2,7	3,1
3	67,1	64	319	149	0	0	468	4,17	3,8	2,8	2,8
4	67,2	60	375	74	0	49	498	3,67	3,8	1,9	3,1
5	68	66	352	251	0	46	649	4,01	3,9	2,2	3,0
6	67,6	55	99	342	76	0	516	3,89	3,9	2,5	3,0
7	67,9	62	21	72	42	51	186	3,97	3,7	2,7	2,9
8	67,1	71	570	0	0	47	617	3,78	3,9	2,2	2,5
9	67,8	53	19	155	0	51	226	3,78	3,9	2,4	2,5
10	67,6	69	250	133	0	0	383	3,73	3,8	2,5	2,2
11	66,4	58	20	178	0	46	244	3,86	3,8	2,4	2,7
12	67,6	63	306	109	0	0	415	3,77	3,8	2,6	2,3
13	66,7	56	305	176	73	0	553	3,97	3,9	2,2	2,6
14	67,7	58	24	147	86	0	257	3,99	3,8	2,4	2,6
15	67,3	59	383	0	176	0	559	3,95	3,8	2,6	2,3
16	67,9	55	261	0	0	0	261	3,89	3,7	2,7	2,3
17	68,3	65	463	0	0	36	499	3,60	3,7	2,8	2,3
18	68,3	57	322	58	103	29	512	3,87	3,8	2,6	2,3
19	68,2	61	21	0	0	0	21	3,94	3,8	2,2	2,1
20	68,4	56	68	50	0	34	151	3,85	3,8	2,2	2,7
21	66,7	63	22	56	236	0	314	3,87	3,8	2,6	2,3
22	67,7	66	346	0	51	31	427	3,89	3,6	2,0	2,7
23	68,3	57	80	88	123	0	291	3,81	3,7	2,0	2,4
24	67,6	58	319	142	81	0	543	3,70	3,8	2,2	2,1
25	67	63	20	139	147	0	306	3,66	3,8	2,1	2,4
26	67,8	61	620	148	0	0	768	3,62	3,8	2,3	2,3
27	67,3	54	153	0	0	39	192	3,74	3,7	2,2	2,3
28	66,8	65	269	0	0	33	301	3,80	3,8	2,1	2,4
29	66,8	65	211	34	42	0	287	3,79	3,6	2,2	2,3
30	67,7	66	19	0	0	0	19	3,83	3,6	2,1	2,1
<b>Mittelwert</b>	67,5	61	228	90	41	16	375	3,84	3,8	2,4	2,5
<b>Std.-Abw.</b>	0,5	5	188	84	63	21	193	0,13	0,1	0,3	0,4

## Anhang C

### Studieninformation, Einverständniserklärung und Datenschutzpassus



**Informationen zur Studie „Analyse und  
Prognose von Trainingswirkungen.  
Multivariate Zeitreihenanalyse mit künstlichen  
neuronalen Netzen“**

Universität Stuttgart, Institut für Sport- und Bewegungswissenschaft  
Allmandring 28, 70569 Stuttgart – Fon 0711-68563166 Fax 0711-68563165

**Studieninformation**

Die richtige Gestaltung von Trainingsbelastungen ist ein entscheidender Faktor, wenn es darum geht, zu einem Wettkampfhöhepunkt die Top-Form zu erreichen. Die Trainingswissenschaft beschäftigt sich daher seit langem damit, den Zusammenhang zwischen Training (Input) und Entwicklung der Leistungsfähigkeit (Output) zu untersuchen. Modelle, die diesen Zusammenhang beschreiben, sollen zukünftig die Trainingssteuerung unterstützen (Trainingswirkungsmodelle). Am Institut für Sport- und Bewegungswissenschaft der Universität Stuttgart wird derzeit ein solches Modell entwickelt. Die Validierung dieses Modells erfolgt mit den Trainings- und Leistungsdaten der Versuchspersonen, die an diesem Forschungsvorhaben teilnehmen.

Im Rahmen dieser Studie wird täglich der Trainingsumfang und die Belastungsintensität (Herzfrequenzmessung während des Trainings) protokolliert. Alle drei Tage wird der Erholungs-/Belastungszustand mit einem Fragebogen bestimmt. Diese Daten dienen als Inputdaten für die Trainingswirkungsmodellierung. Damit die Wirkungen des Trainings diagnostiziert werden können, werden verschiedene Outputdaten täglich bzw. alle drei Tage erhoben:

- physiologische Basisparameter Ruhepuls und Körpermasse (täglich)
- Diagnostik der Ausdauerleistungsfähigkeit. Alle drei Tage wird mit einer spiroergometrischen (Atemgasanalyse über eine Maske) Untersuchung auf einem Radergometer die Ausdauerleistungsfähigkeit gemessen.

Der Trainingsinput, der Fragebogen und die physiologischen Basisparameter werden selbständig von den Studienteilnehmern auf einem mobilen Datenerfassungsgerät erhoben. Die Ausdauerdiagnostik findet alle drei Tage am Institut für Sport- und Bewegungswissenschaft der Universität Stuttgart statt.

**Abbildung C.1:** Studieninformation





**Einverständniserklärung zur  
Studienteilnahme**

**Version 2009**

Universität Stuttgart, Institut für Sport- und Bewegungswissenschaft  
Allmandring 28, 70569 Stuttgart – Fon 0711-68563186 Fax 0711-68563165

*UNIVERSITÄT STUTTGART, INSTITUT FÜR SPORT- UND BEWEGUNGSWISSENSCHAFT, PROF. DR.  
W. ALT UND BENJAMIN HAAR, 0711-68563186, MULTIVARIATE ZEITREIHENMODELLIERUNG  
VON TRAININGSWIRKUNGEN MIT NEURONALEN NETZEN*

**Einverständniserklärung zur Studienteilnahme**

**Analyse und Prognose von Trainingswirkungen. Multivariate  
Zeitreihenanalyse mit künstlichen neuronalen Netzen**

Hiermit bestätige ich, dass ich über die Ziele, die Dauer, den Ablauf, den Nutzen sowie die Risiken der Studienteilnahme aufgeklärt wurde. Ich wurde darüber informiert, dass die Teilnahme an den Untersuchungen freiwillig ist und dass mein Einverständnis zur Teilnahme jederzeit ohne Angabe von Gründen und ohne Nachteile widerrufen werden kann. Ich wurde über die Bedingungen einer Probandenversicherung aufgeklärt. Ich wurde über die Verwendung der erhobenen Daten informiert und habe gesondert der Verwendung der Daten zugestimmt.

Stuttgart, den

Unterschrift

Name des Patienten/der Patientin in  
Blockschrift

**Abbildung C.2:** Einverständniserklärung



**Information und Einwilligungserklärung zur  
Erhebung und Verwendung der erhobenen  
Daten einer wissenschaftlichen  
Untersuchung**

**Version 2009**

Universität Stuttgart, Institut für Sport- und Bewegungswissenschaft  
Allmandring 28, 70569 Stuttgart – Fon 0711-68563186 Fax 0711-68563165

*UNIVERSITÄT STUTTGART, INSTITUT FÜR SPORT- UND BEWEGUNGSWISSENSCHAFT, PROF. DR.  
W. ALT UND BENJAMIN HAAR, 0711-68563186, MULTIVARIATE ZEITREIHENMODELLIERUNG  
VON TRAININGSWIRKUNGEN MIT NEURONALEN NETZEN*

**Information zum Datenschutz**

Ihre im Rahmen der wissenschaftlichen Untersuchung erhobenen Daten werden vertraulich behandelt und ausschließlich in verschlüsselter Form weitergegeben. Die für die wissenschaftliche Untersuchung wichtigen Daten werden in verschlüsselter (pseudonymisiert, ohne Namensnennung) Form in einer gesonderten elektronischen Datenbank eingetragen.

Die Zuordnung der verschlüsselten Daten zu Ihrer Person ist nur anhand einer Probandenliste möglich, die in einem verschlossenen Schrank, getrennt von den Studienunterlagen aufbewahrt wird und nur dem Studienleiter zugänglich ist. Die Daten werden für die Dauer von 7 Jahren am Institut für Sport- und Bewegungswissenschaft der Universität Stuttgart aufbewahrt. Sollten Sie von der Studie zurücktreten, werden die bereits vorliegenden Daten vernichtet.

**Einwilligungserklärung**

**Ich erkläre mich der Verwendung der im Rahmen der Studie „Analyse und Prognose von Trainingswirkungen. Multivariate Zeitreihenanalyse mit künstlichen neuronalen Netzen“ erhobenen Daten in der oben beschriebenen Weise einverstanden. Ich kann jeder Zeit meine Daten beim Studienleiter einsehen.**

Stuttgart, den \_\_\_\_\_

Unterschrift \_\_\_\_\_

Name des Patienten/der Patientin in  
Blockschrift \_\_\_\_\_

**Abbildung C.3:** Datenschutzpassus

# Lebenslauf

## Benjamin Haar

---

### Persönliches

Geburtsort Kirchheim/Teck  
Geburtsdatum 13. Januar 1980

### Ausbildung

1986-1990 Grundschule Hochdorf  
1990-1999 Gymnasium Plochingen  
2001-2006 Studium Diplom Sportwissenschaft an der Universität Stuttgart

### Beruf

2002-2006 studentische Hilfskraft, Institut für Sport- und Bewegungswissenschaft  
der Universität Stuttgart  
2006 wissenschaftliche Hilfskraft, Institut für Sport- und Bewegungswissenschaft  
der Universität Stuttgart  
seit 2006 akademischer Mitarbeiter, Institut für Sport- und Bewegungswissenschaft  
der Universität Stuttgart

### Zivildienst

2001 Rettungssanitäter, DRK Kreisverband Nürtingen/Kirchheim

# Erklärung

Hiermit versichere ich an Eides statt, dass ich die vorliegende Arbeit mit dem Titel „Analyse und Prognose von Trainingswirkungen. Multivariate Zeitreihenanalyse mit künstlichen neuronalen Netzen“ selbstständig ohne unerlaubte Hilfe und ohne Benutzung anderer als der angegebenen Hilfsmittel angefertigt haben. Alle Stellen, die wörtlich oder sinngemäß aus Veröffentlichungen oder aus anderweitigen fremden Äußerungen entnommen wurden, habe ich als solche einzeln kenntlich gemacht. Die Arbeit wurde bisher in gleicher oder ähnlicher Form keiner anderen Prüfungskommission vorgelegt und auch nicht veröffentlicht.

Ort, Datum und Unterschrift

# Danksagung

**DANKE!**

Marie-Luise Conrad, Ingrid Haar, Gerhard Haar & Stefanie Lübbe mit Familie  
Prof. Dr. Wilfried Alt & Prof. Dr. Edelmann-Nusser  
Sonja Gabriel, Jörg Gokeler, Florian Sievers & Steffen Hepperle  
Dr. Julia Buhlmeier, Julia Thurn, Dr. Claudia Reule, Tille Rupp,  
Dr. Dieter Bubeck, PD Dr. Rolf Brack, Dr. Uwe Gomolinsky,  
Dr. Harald Hochwald, Dr. Herbert Leikov & Dr. Syn Schmitt  
Annika Müller & PD Dr. Karlheinz Herrmann  
Armin Kamm & Josef Lopez