



Bundesinstitut  
für Sportwissenschaft



Wir helfen  
dem Sport

Alexander Hagg · Alexander Asteroth · Christian Rasche · Kevin Bach ·  
Mark Pfeiffer

# Künstliche Intelligenz für den Spitzensport im Spannungsfeld zwischen Big und Small Data

(KISs-BiS)



Alexander Hagg · Alexander Asteroth · Christian Rasche ·  
Kevin Bach · Mark Pfeiffer

# Künstliche Intelligenz für den Spitzensport im Spannungsfeld zwischen Big und Small Data

(KISs-BiS)

SPORTVERLAG *Strauß*

## Schriftenreihe des Bundesinstituts für Sportwissenschaft 2021 | 03

### **Bibliografische Information der Deutschen Nationalbibliothek**

Die Deutsche Nationalbibliothek verzeichnet diese Publikation in der Deutschen Nationalbibliografie; detaillierte bibliografische Daten sind im Internet über <http://dnb.d-nb.de> abrufbar.

#### **Herausgeber:**

Bundesinstitut für Sportwissenschaft (BISp)  
Graurheindorfer Str. 198  
53117 Bonn  
[www.bisp.de](http://www.bisp.de)

#### **Ansprechpartner:**

Frau Katharina Schorr  
Graurheindorfer Straße 198  
53117 Bonn  
[katharina.schorr@bisp.de](mailto:katharina.schorr@bisp.de)  
[www.bisp.de](http://www.bisp.de)  
Tel.: +49 228 99 640 9062

Hagg, Alexander; Asteroth, Alexander; Rasche, Christian; Bach, Kevin; Pfeiffer, Mark

### **Künstliche Intelligenz für den Spitzensport im Spannungsfeld zwischen Big und Small Data (KISs-BiS)**

Sportverlag Strauß, Hellenthal – 1. Aufl. 2021

(Schriftenreihe des Bundesinstituts für Sportwissenschaft, Bd. 2021,03)

ISBN 978-3-86884-551-8 (Print)

ISBN 978-3-86884-718-5 (E-Book)

Das Werk einschließlich aller seiner Teile ist urheberrechtlich geschützt.

Kein Teil dieses Werkes darf ohne ausdrückliche Genehmigung des Bundesinstituts für Sportwissenschaft digital oder analog vervielfältigt werden.

Die Empfehlungen und Erhebungsinstrumente in diesem Manual wurden von den Autoren und dem Verlag (Bundesinstitut für Sportwissenschaft) sorgfältig erwogen und geprüft. Dennoch kann keine Garantie übernommen werden, dass Daten fehlerinterpretiert bzw. unsachmäßige Interventionen erfolgen. Eine Haftung der Autoren, des Herausgebers bzw. des Verlages und seiner Beauftragten für Personen-, Sach- und Vermögensschäden ist ausgeschlossen.

### **© SPORTVERLAG Strauß**

Neuhaus 12 – 53940 Hellenthal

Fon (+49 2448) 247 00 40 - Fax (+49 2448) 919 56 10

E-Mail: [info@sportverlag-strauss.de](mailto:info@sportverlag-strauss.de)

<http://www.sportverlag-strauss.de>

Satz & Layout: Mike Hopf, Berlin

Umschlag: Mike Hopf, Berlin

Umschlagillustration: AdobeStock (Olga)

Herstellung: CPI Druckdienstleistungen GmbH

Ferdinand-Jühlke-Straße 7, 99095 Erfurt

Printed in Germany

# Inhaltsverzeichnis





# Inhaltsverzeichnis

	<b>Tabellenverzeichnis</b> .....	<b>9</b>
	<b>Abbildungsverzeichnis</b> .....	<b>13</b>
	<b>Vorbemerkung</b> .....	<b>19</b>
<b>1</b>	<b>Einführung</b> .....	<b>23</b>
<b>2</b>	<b>Was ist Künstliche Intelligenz?</b> .....	<b>27</b>
<b>3</b>	<b>Methoden und Anwendungsbereiche der KI</b> .....	<b>33</b>
3.1	S: Sensorik, Messung und Wahrnehmung .....	33
3.1.1	Maschinelles Sehen. ....	33
3.1.2	Wearables, Sensorik & Realzeitverfahren für große Datenmengen. ....	35
3.1.3	Multimodale Daten. ....	36
3.2	M: Modellierung, Lernen und Vorhersage .....	37
3.2.1	Deep Learning .....	38
3.2.2	Transferlernen .....	43
3.2.3	Erklärbarkeit (Explainability) .....	44
3.2.4	Robustes Lernen .....	47
3.2.5	Statistische („Grey-Box“) Modellierungsmethoden .....	48
3.2.6	Fehler- und Risikoerkennung .....	49
3.2.7	Verarbeitung menschlicher Sprache .....	49
3.2.8	Verteiltes Lernen (Federated Learning) .....	50
3.2.9	Automatisiertes vs. augmentiertes Lernen. ....	51
3.2.10	Small Data. ....	52
3.2.11	Dedizierte Hardware .....	56
3.3	P: Planung, Strategie und Optimierung .....	56
3.3.1	Integration der Teilschritte S, M und P (direkte Verknüpfung) .....	57
3.3.2	Lösungsdiversität. ....	57
3.3.3	Multiple Kriterien .....	59
3.3.4	Effiziente Optimierung. ....	59

3.3.5	Robuste Optimierung .....	60
3.3.6	Reinforcement Learning.....	61
3.4	I: Intervention, Interaktion und Manipulation .....	62
3.4.1	Mensch-Maschine-Interaktion.....	62
3.4.2	Simulation / VR / AR.....	65
3.4.3	Dimensionsreduktion und Visualisierung.....	67
<b>4</b>	<b>Möglichkeiten der KI im Spitzensport .....</b>	<b>71</b>
4.1	Methodologischer Mismatch .....	71
4.2	Struktureller Mismatch .....	74
4.3	Mangelnde Awareness .....	75
<b>5</b>	<b>Use Cases .....</b>	<b>79</b>
5.1	Trainingssteuerung .....	79
5.1.1	Methodische Festlegungen des anwendungsspezifischen SMPI-Zyklus.....	81
5.1.2	S: Sensorik, Messung und Wahrnehmung (Datenerfassung) .....	82
5.1.3	M: Modellierung, Lernen und Vorhersage .....	85
5.1.4	P: Planung, Strategie und Optimierung .....	90
5.1.5	Prototypische Umsetzung des SMPI-Zyklus .....	92
5.1.6	Diskussion und Ausblick.....	100
5.2	Wettkampfdiagnostik in den Sportspielen.....	102
5.3	Leistungsdiagnostik in multitechnischen Individualsportarten.....	105
<b>6</b>	<b>Handlungsempfehlungen.....</b>	<b>111</b>
6.1	Daten- und Methodenlage .....	111
6.2	S: Sensorik, Messung und Wahrnehmung .....	113
6.3	M: Modellierung, Lernen und Vorhersage .....	115
6.4	P: Planung, Strategie und Optimierung .....	117
6.5	I: Intervention, Interaktion und Manipulation .....	118
6.6	Allgemeine Empfehlungen für die Forschungsförderung ..	120
<b>7</b>	<b>Abschließende Beurteilung von KI im Spitzensport ...</b>	<b>123</b>
<b>8</b>	<b>Literaturverzeichnis.....</b>	<b>127</b>



# Tabellenverzeichnis





# Tabellenverzeichnis

Tab. 1: .....	84
Übersicht der für den KI-Schritt S (Wahrnehmung und Sensorik) erhobenen Parameter bezüglich des Trainings. Die im realisierten Use Case im Radfahren exemplarisch genutzten Informationen sind fett markiert.	
Tab. 2: .....	94
Zusammenfassende Parameter- und Modellauswahl im Rahmen der vorliegenden prototypische Umsetzung eines SMPI-Kreislauf für den Use Case Trainingssteuerung im Radsport.	



# Abbildungsverzeichnis





# Abbildungsverzeichnis

Abb. 1:	29
Allgemeine Darstellung eines KI-Modells (in Anlehnung an Russel & Norvig, 2020).	
Abb. 2:	30
Der SMPI-Handlungszyklus und Komponenten eines intelligenten Agenten und Interaktion mit der Umgebung (Sportler und Sportlerin) am Beispiel der Trainingssteuerung.	
Abb. 3:	34
Beispielhafter Datenfluss in einem System des Maschinellen Sehens (vgl. Weinland et al., 2011).	
Abb. 4:	72
Datenmenge und Vorhersagefehler für Small und Big Data im Vergleich (vgl. Hestness, 2017).	
Abb. 5:	79
Die Interaktion eines KI-Systems mit seiner Umgebung. Durch Wahrnehmung kann ein Modell gelernt werden, welches dazu verwendet wird, eine Strategie zu entwickeln, die durch Intervention auf die Umgebung angewendet werden kann.	
Abb. 6:	83
Exemplarische Darstellung der Trainingsdauer unter- und oberhalb der VT2 (blaue/rote Balken, vgl. Abschnitt S/1) und der virtuellen Leistungsfähigkeit (rote Kreuze, vgl. S/2 und M/1) von Proband 1 im Verlauf des Studienzeitraums von August bis Dezember 2020.	
Abb. 7:	86
Beispielhafte Darstellung eines synthetischen Belastungsprofils („Benchmark“, blaue Linie), welches für die Bestimmung der	

virtuellen Leistungsdiagnose verwendet wurde, sowie die hierzu korrespondierende HF-Kurve (orange Linie) mit dem hierzu errechneten TRIMP-Wert [gewichtete Fläche unterhalb der HF-Kurve].

Abb. 8: ..... 89

Schematische Darstellung des antagonistischen Performance-Potential Double-Modells (kurz: PerPot DoMo) inklusive Anknüpfungsfaktoren (schwarze Pfeile). (Perl & Pfeiffer, 2011)

Abb. 9: ..... 92

Zwei unterschiedliche Intervalltrainings (links) können durch charakteristische Merkmale beschrieben/generiert werden. Diese Merkmale können als Punkte (farbige Kreuze) in einem n-dimensionalen Raum (hier 3D) verstanden werden.

Abb. 10: ..... 95

Ausgestaltung des SMPI-KI-Kreislaufs inklusive Elemente der Benutzerinteraktion (orange hinterlegt) und kontextuellen Informationen (pink hinterlegt) für den Use Case Leistungssteuerung im Radsport. Das Trainingsziel (orange Umrandung) wird in der vorliegenden Umsetzung aus den empirischen Daten selbst abgeleitet, könnte aber theoretisch auch durch Nutzerinteraktion festgelegt werden.

Abb. 11: ..... 97

In einem Dialogfenster wird die wöchentliche Trainingssequenz (im oberen Teil des Bildes als Balkendiagramm dargestellt) mit der hierzu erwartenden Leistungsentwicklung (im unteren Teil des Bildes als roter Liniengraph dargestellt) für einen konkreten Trainingsvorschlag gegenübergestellt. Die grünen Linien im unteren Teil des Bildes veranschaulichen die voraussichtliche Leistungsentwicklung für die restlichen vier Trainingssequenzen.

Abb. 12: ..... 98

Darstellung eines exemplarischen Workouts, welches eine vorgegebene Trainingsdauer ober- und unterhalb der VT2 für eine



Trainingseinheit an einem Tag aus der bereits zuvor ausgewählten Trainingssequenz konkretisiert.

Abb. 13: .....99  
Exemplarische Darstellung eines Saisonverlaufs, in dem das Training mit der Leistungsentwicklung gegenübergestellt wird. Hierbei stellen die nicht transparenten Säulen Trainingstage dar, an denen bereits trainiert wurde, wohingegen die transparenten Säulen die noch ausstehenden Trainingseinheiten darstellen. Analog dazu stellt die grüne durchgezogene Linie die Leistungsentwicklung dar, die dem bereits durchgeführten Training zugrunde lag, und die gestrichelte Linie die Leistungsentwicklung, die bei der Durchführung des noch ausstehenden Trainings zu erwarten ist. Mit den Kreuzen werden die einzelnen Fitnessziele in der Saison dargestellt.

Abb. 14: .....123  
Verhältnis von Risiko, Potenzial und Anwendbarkeit der KI im Spitzensport im Hinblick auf den Prozess von der Sensorik über die Modellierung und Planung bis zur Intervention und damit dem Schließen des KI-Kreislaufes



# Vorbemerkung





Im April 2019 wurde vom Bundesinstitut für Sportwissenschaft (BISp) im Rahmen der Forschungsförderung die Expertise „Einsatzgebiete von Künstlicher Intelligenz (KI) im Spitzensport“ ausgeschrieben. Gefördert wurde anschließend das Projekt „Künstliche Intelligenz für den Spitzensport im Spannungsfeld zwischen Big und Small Data (KISs-BiS)“, welches zwei in sich geschlossene Arbeitspakete umfasst. Der nachfolgende Bericht bezieht sich auf die gemeinsam von den Arbeitsgruppen Prof. Alexander Asteroth (Hochschule Bonn-Rhein-Sieg, HBRS) und Prof. Mark Pfeiffer (JGU Mainz) bearbeiteten Projektaufgaben. Im Laufe des Projekts wurde der Aufgabenbereich dahingehend erweitert, dass mit der Umsetzung eines Use Cases zur Trainingssteuerung im Radsport (Kapitel 5.1) ein empirischer Teil in die Expertise aufgenommen worden ist.



# Einführung

1





Künstliche Intelligenz (KI) ist aus der heutigen Gesellschaft kaum noch wegzudenken. So wird KI u. a. in Anwendungsszenarien wie Autonomes Fahren oder – ganz aktuell – für die Suche und Erforschung von Impfstoffen eingesetzt. Auch im Sport haben Methoden der KI in den letzten Jahren mehr und mehr Einzug gehalten. Ob und inwieweit dabei allerdings die derzeitigen Potenziale der KI tatsächlich ausgeschöpft werden, ist bislang nicht untersucht worden.

Der Nutzen von Methoden der KI im Sport ist unbestritten, jedoch treten bei der Umsetzung in die Praxis gravierende Probleme auf, was den Zugang zu Ressourcen, die Verfügbarkeit von Experten und den Umgang mit den Methoden und Daten betrifft. Die Ursache für die, verglichen mit anderen Anwendungsgebieten, langsame An- bzw. Übernahme von Methoden der KI in den Spitzensport ist nach unserer Hypothese auf mehrere Mismatches zwischen dem Anwendungsfeld und den KI-Methoden zurückzuführen. Diese Mismatches sind *methodischer*, *struktureller* und auch *kommunikativer* Art.

Ausgehend von den Ergebnissen eines narrativen Reviews werden Vorschläge abgeleitet, die zur Auflösung der Mismatches führen können und zugleich neue Transfer- und Synergiemöglichkeiten aufzeigen. Diese können wiederum die Basis für neue innovative (Produkt-)Entwicklungen legen. In drei Use Cases zu Trainingssteuerung, Leistungsdiagnostik und Wettkampfdiagnostik wird dies exemplarisch in Form entsprechender Projektbeschreibungen umgesetzt. Diese wurden den Zielgruppen entsprechend aufbereitet, wobei die Akteure im Spitzensport im Fokus stehen.

Das grundlegende Ziel der vorliegenden BISp-Expertise *Künstliche Intelligenz für den Spitzensport im Spannungsfeld zwischen Big und Small Data* besteht darin, die Kluft zwischen den Methoden/Ansätzen der Künstlichen Intelligenz auf der einen und dem Anwendungsfeld des Spitzensports auf der anderen Seite aufzuzeigen. Daran anknüpfend sollen Möglichkeiten beschrieben werden, wie sich diese Kluft überbrücken lässt. Letzteres scheint von weitreichender Bedeutung für die zukünftige internationale Wettbewerbsfähigkeit des deutschen Spitzensports zu sein, da sich andere Länder womöglich bereits einen Vorsprung erarbeitet ha-

ben. Im vorliegenden wird daher der internationale Status Quo des Einsatzes von KI im Spitzensport erhoben, um ein möglichst aussagekräftiges Benchmark zu setzen, wohin die Entwicklung gehen kann bzw. sollte.

In die Expertise fließen die vielfältigen Erfahrungen der Antragsteller ein mit dem Ziel, einen Überblick über die derzeitigen nationalen und internationalen Einsatzgebiete und den Nutzen von KI, insbesondere des maschinellen Lernens, im Spitzensport aufzuzeigen. Die Grenzen und Potenziale von KI-Anwendungen lassen sich insbesondere bei Betrachtung der Transfermöglichkeiten aus anderen Anwendungsgebieten abschätzen. Dabei sind die typischen Strukturen des Spitzensports zu berücksichtigen. Ebenfalls wird aufgedeckt, in welchen Bereichen KI noch nicht eingesetzt werden kann und ob bzw. wie diese Situation verändert werden kann. Hier ist eine Inventarisierung der Zugänglichkeit benötigter Datenmengen und deren Informationsgehalt eine notwendige Voraussetzung.

Die folgenden Herausforderungen werden besonders betrachtet:

- › Methodisch: es ist unklar, wie mit den verfügbaren Daten (Menge/Umfang, Qualität, Validität etc.) umgegangen werden soll, d. h. wie man von den Daten zu nutzbaren Informationen gelangt.
- › Ressourcen: nicht alle Sportler und Sportlerinnen oder Verbände haben gleichermaßen Zugriff auf Wissen und Ressourcen. Die Verfügbarkeit von Data Scientists wird dadurch begrenzt, dass der Spitzensport im direkten Wettbewerb mit der Industrie steht.
- › Das Potenzial von KI sowie die Art und Weise, wie sich KI im Spitzensport einsetzen lässt, wird derzeit noch unzureichend mit den jeweiligen Zielgruppen kommuniziert.

Zunächst wird in Kapitel 2 kurz erläutert, welches Begriffsverständnis von KI der Expertise zugrunde liegt. Anschließend wird sich in Kapitel 3 dem aktuellen Stand der Forschung zu Methoden

und Anwendungsbereichen der KI gewidmet, wobei sich die Gliederung an den vier Teilschritten der KI orientiert. Die Ausführungen sind von dem Anspruch geprägt, den Transfer, der aus anderen Anwendungen der KI auf den Gegenstand des Spitzensports übertragen werden kann, in den Mittelpunkt zu stellen. In Kapitel 4 werden konkrete Hinweise zur Anwendung von KI im Spitzensport unter Berücksichtigung der besonderen Rahmenbedingungen und der Gegenstandsbereiche gegeben. Im weiteren Verlauf des Berichts werden im 5. Kapitel drei Use Cases von den Projektpartnern der HBRS und der JGU Mainz entwickelt, welche exemplarisch drei potenzielle Projekte in den Bereichen Trainingssteuerung, Leistungsdiagnostik sowie Wettkampfdiagnostik beschreiben. Dabei soll die Ausarbeitung dieser Use Cases aufzeigen, auf welche Art und Weise Probleme, die heute noch bei der Verbindung zwischen KI und Sport bestehen, möglichst ausgeräumt werden können. Eine empirische Umsetzung des Use Case zur Trainingssteuerung erfolgte im Radsport, weshalb dieser ausführlicher dargestellt wird. Abschließend werden in Kapitel 6 konkrete Handlungsempfehlungen für ausgewählte Themenbereiche abgeleitet.



# Was ist Künstliche Intelligenz?

2



In einem ersten Schritt widmen wir uns der Frage, wie sich Künstliche Intelligenz (KI) genau definieren lässt, beziehungsweise welche Definition von KI für dieses Forschungsprojekt zugrunde gelegt wird.

Das Fachgebiet *Künstliche Intelligenz* (KI) ist ein Teilgebiet der Informatik und existiert als solches bereits seit den 1950er Jahren. In den letzten Jahren hat die Anwendung von KI in vielen Bereichen an Bedeutung gewonnen und es wurden teils beeindruckende Ergebnisse erzielt. KI beschäftigt sich mit intelligentem Verhalten durch Maschinen. In den führenden Lehrbüchern wird in diesem Zusammenhang heute von intelligenten Agenten bzw. Akteuren gesprochen. Legt man die Definition von Russel und Norvig (2020) zugrunde, dann lassen sich bei einem KI-Agent bzw. KI-System im Wesentlichen vier Teilschritte (Abk. „SMPI“) voneinander unterscheiden:

**S:** Sensorik, Messung und Wahrnehmung

**M:** Modellierung, Lernen und Vorhersage

**P:** Planung, Strategie und Optimierung

**I:** Intervention, Interaktion und Manipulation

Ein KI-Agent kann seine Umgebung durch Interaktion beeinflussen. Hierzu muss die KI die Umgebung zuerst mit Hilfe einer Sensorik wahrnehmen, welche die physikalische bzw. phänomenologische Welt in maschinenlesbare Daten umwandelt (Abb. 1).

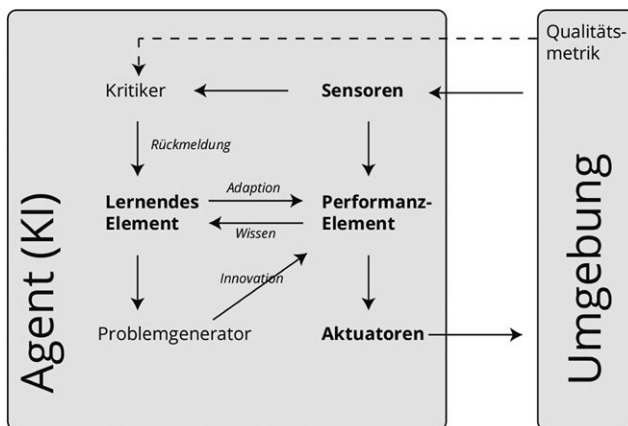


Abb. 1: Allgemeine Darstellung eines KI-Modells (in Anlehnung an Russel & Norvig, 2020).

Diese Daten werden dazu verwendet, eine interne Darstellung der Umgebung innerhalb des Agenten zu modellieren, Modelle anzupassen, zu lernen, um somit in der Lage zu sein, Vorhersagen zu treffen (sog. Kritikerkomponente). Diese Ist-Beschreibung in Kombination mit den Vorhersagen formen die Basis für die Planungsphase, welche die Umgebung in eine Soll-Situation bringen soll. Das lernende Element kann mittels eines sogenannten Problemgenerators konkrete Beispiele generieren, welche dann (sog. Performanz-Elemente) dazu eingesetzt werden, Handlungen oder Handlungsempfehlungen an die Umgebung weiterzureichen. Dies erfolgt durch Interventionen und Interaktionen, welche über sogenannte Aktuatoren ausgeführt werden. Solche Aktuatoren sind zum Beispiel in der Robotik häufig mechanische Arme, können aber auch Displays sein, welche Handlungsempfehlungen an die Nutzenden/Sportler und Sportlerinnen (die „Umgebung“ des KI-Systems) weiterreichen. Übertragen auf den Spitzensport könnte ein KI-System beispielsweise zur Trainingssteuerung eingesetzt werden (vgl. Abb. 2).

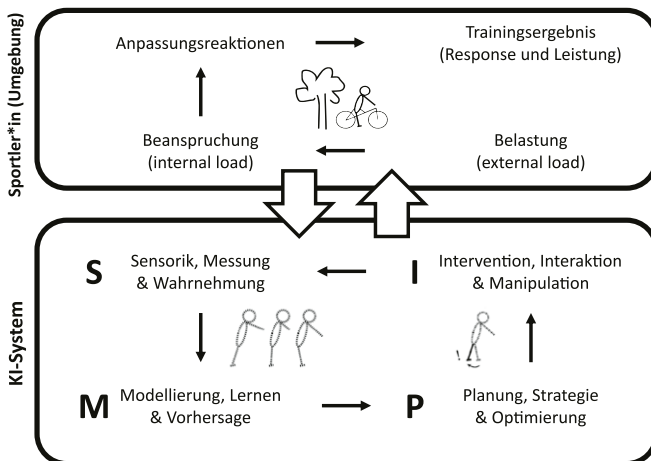


Abb. 2: Der SMPI-Handlungszyklus und Komponenten eines intelligenten Agenten und Interaktion mit der Umgebung (Sportler und Sportlerin) am Beispiel der Trainingssteuerung.

Das in Abbildung 2 dargestellte KI-System wird im Zusammenhang mit dem Use Case „Trainingssteuerung“ in Kapitel 5.1 detailliert beschrieben.



# Methoden und Anwendungsbereiche der KI



Die KI umfasst aktuell eine große Vielfalt an Methoden und Anwendungsgebieten. In diesem Kapitel wird daher ein Überblick gegeben, indem zunächst ein Stand der angewandten Forschung präsentiert wird. Danach identifizieren wir die Kernprobleme in der KI, welche auch die Grenzen und Spannungsfelder in der angewandten KI verdeutlicht. Schließlich fassen wir zusammen, welche Voraussetzungen erfüllt werden müssen, um einen KI-Agenten zu konstruieren.

Der Forschungsstand wird entsprechend der genannten vier Teilschritte der KI (vgl. Kap. 3 und Abb. 2) gegliedert. Ein Großteil der Fortschritte in der KI basiert auf einer rasanten Entwicklung in den Bereichen Machine Learning (ML) und Digitaltechnik. Dies hat beispielsweise dazu geführt, dass, bedingt durch die intensive Nutzung sozialer Netzwerke, die Verarbeitung der menschlichen Sprache in den letzten zwei Jahrzehnten deutlich vorangeschritten ist.

## 3.1 S: Sensorik, Messung und Wahrnehmung

### 3.1.1 Maschinelles Sehen

Verfahren für Bilderkennung und maschinelles Sehen (Computer Vision) werden inzwischen sehr häufig für Handlungserkennung eingesetzt, mit vielen grundlegenden Anwendungen in der Robotik, der Videoüberwachung und der Mensch-Computer-Interaktion. Die Zahl der Publikationen nimmt insbesondere auch im Bereich der Aktionserkennung stetig zu. Eine umfassende Übersicht und Kategorisierung der verwendeten Ansätze liefert Weinland et al. (2011). Die Autoren konzentrieren sich auf Ansätze, die auf eine Klassifizierung von Ganzkörperbewegungen abzielen, wie z. B. Treten und Schlagen, wobei visuelle Daten als Eingabestrom dienen. Abbildung 3 zeigt, wie ein typischer Datenfluss solch eines Systems definiert ist. Aus Videomaterial werden Merkmale extrahiert, welche dann dazu verwendet werden können, Aktionen zu segmentieren, zu klassifizieren und zu lernen. Merkmale im Sportbereich könnten zum Beispiel sein: Farbe der Kleidung, feste Muster auf

Kleidung oder QR Codes. Einfache, unbearbeitete Eingangsdaten (raw data), z. B. Farbdaten der Kamerapixel, werden dabei als Low Level Features bezeichnet. Auf Basis dieser Eingangsdaten können sogenannte High Level Features extrahiert werden. Dies erfolgt entweder manuell oder durch die Modelle des maschinellen Lernens.

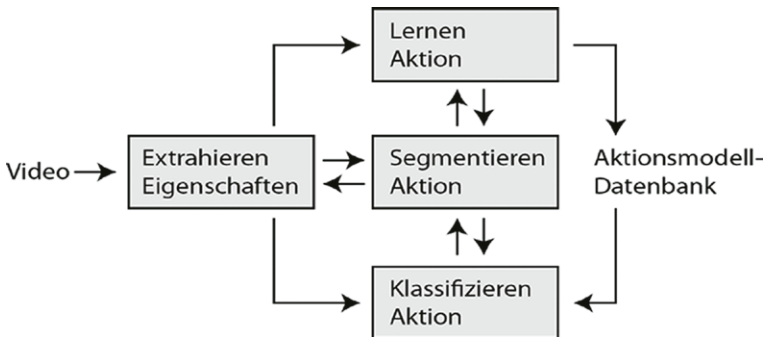


Abb. 3: Beispielhafter Datenfluss in einem System des Maschinellen Sehens (vgl. Weinland et al., 2011).

Ein typischer Datenfluss für ein generisches Aktionserkennungssystem umfasst voneinander abhängige Stufen der Merkmalsextraktion, des Lernens, der Segmentierung und der Klassifikation (Weinland et al., 2011).

Es gibt immer noch einige wichtige Fragen, die in den meisten Arbeiten nicht angesprochen werden: Skalierbarkeit von Aktionserkennungssystemen, Umgang mit unbekanntem Bewegungen, Umgang mit Okklusionen und Szenen mit mehreren Personen.

### Für den Spitzensport bedeutet das:

Die Bewegungserkennung aus Videomaterial ist möglich, aber viele Ansätze können mit unbekanntem Bewegungen, Okklusionen und Szenen mit mehreren Personen nicht umgehen. In Sportarten mit mehreren Teilnehmenden müssen z. B. Bewegungsmodelle entwickelt werden, die bei der Verfolgung einzelner Sportler und Sportlerinnen aufgrund von Okklusionen durch Andere eine Weiterverfolgung ermöglichen.

### 3.1.2 Wearables, Sensorik & Realzeitverfahren für große Datenmengen

In vielen Sportarten muss insbesondere die Verwendung von nicht-visuellen Sensordaten in Betracht gezogen werden. Das immer vielfältigere Angebot an sogenannten Wearables liefert hier einen Großteil der vorhandenen Daten, die in vielen Settings im Spitzensport bereits erhoben und im Rahmen der Belastungs-Beanspruchungssteuerung genutzt werden.

Die Forschung in diesem Bereich steht in vielerlei Hinsicht noch am Anfang und wird aktuell vor allem durch die rasante Entwicklung bei den Fitnessstrackern und -uhren (Smartwatch) dominiert. Ebenso kann die Anbindung tragbarer Geräte an breitere IoT-Ökosysteme neue Dienstleistungen und Interaktionsmodalitäten ermöglichen und schließlich sind gründlichere methodische Ansätze sowohl für die Analyse der User-Bedürfnisse und für die Bewertung technologischer Artefakte zu entwickeln. Ein weiteres, unterentwickeltes Forschungsfeld sind tragbare Geräte, die im Zusammenhang mit sportlichen Aktivitäten in der Rehabilitation (z. B. in der Schmerztherapie und im Bereich serious games) verwendet werden (Mencarini et al., 2019). Auch wenn die Anwendung von Wearables für den Spitzensport sich in einigen Fällen als ungeeignet herausstellen sollte, weil zum Beispiel im Wettbewerb das Tragen der Wearables nicht erlaubt ist, diese bei der Bewegungsausführung hinderlich sind oder technische Voraussetzungen mit dem Spitzensportalltag unvereinbar sind, lassen sich mit Wearables die für eine KI-Anwendung erforderlichen Daten mit geringem messtechnischen Aufwand generieren (Füller et al., 2011; Ludwig et al., 2015, Ludwig et al., 2016a, Ludwig et al., 2016b, Ludwig et al., 2017, Ludwig et al., 2018, Schäfer et al., 2015). Allerdings zeigt die Übersicht von Mencarini et al. (2019), dass von den gesichteten 57 Artikeln nur zehn im Bereich des Spitzensports angesiedelt waren.

Auf dem Gebiet der Sensortechnologie sind die Surveyartikel zu den Themen „Wireless sensor networks“ im medizinischen Bereich wegweisend (Alemdar et al., 2010). Zu nennen sind hier Outlierdetektion in komplexen Umgebungen (Shahid et al., 2015), Fusion von Daten im Bereich Internet of Things (Alam et al., 2017),

Sensornetzwerke für Multiagentsysteme, also die Kooperation zwischen Sensorsystemen (Vinyals et al., 2011), Koordination und Kontrolle von Multikamerasystemen im Sicherheitsbereich (Natarajan et al., 2015) und der Einsatz unbemannter Flugobjekte zur Hilfestellung der Bewegungsplanung in verrauschten Umgebungen (Dadkhah et al., 2012).

**Für den Spitzensport bedeutet das:**

Der Umgang mit größeren Sensornetzwerken lässt sich mit Hilfe aktueller Fusionsmethoden vereinfachen.

Die Kombination von z. B. Kameradaten und Wearables mehrerer Spieler und Spielerinnen kann dazu verwendet werden, um über Positions- und Fitnessdaten strategische oder taktische Situationen/Probleme zu lösen.

**Für den Spitzensport bedeutet das:**

Wearables werden in immer mehr Sportarten eingesetzt, vor allem im Training und bei der Rehabilitation.

Es muss beachtet werden, in welchen Situationen Wearables sinnvoll anwendbar sind.

### 3.1.3 Multimodale Daten

Auch die Verwendung multimodaler Kamerasysteme, die sowohl Farbbilder als auch Tiefendaten kombinieren, hat spätestens seit dem Transfer solcher Lösungen von der Spieleindustrie in die Robotik dazu beigetragen, dass die Bewegungserkennung aber auch Objektklassifizierung in komplexen Umgebungen mit dreidimensionalen Daten angereichert werden können und die Extraktion von Skelettmodelldaten aus sich bewegenden Menschen ermöglicht wurde (Lun et al., 2015; Hagg et al., 2016; Wang et al., 2018a). Große, multimodale Trainingsdatensätze stehen hier zur freien Verfügung (z. B. Shahroudy et al., 2016; Liu et al., 2019). Einige, aber nicht alle, für den Sport verwertbare Aktionsabläufe sind in den Datensätzen vertreten. Allerdings kann der Transfer zu datenarmen Bereichen

des Spitzensports, auch in Kombination mit Daten aus den datenreicheren Bereichen, erfolgen. Diese Art des Lernens, Transferlearning genannt, wird in Kapitel 3.2.2 weiter behandelt.

Die Robustheit der Wahrnehmung in KI-Systemen, gegen unter anderem Rauschen und Sensorschwächen, kann in vielen Fällen durch die Benutzung mehrerer Sensorarten erhöht werden (Stichwort: sensor fusion). Beispiele findet man bei der Gestenerkennung (Nishida et al., 2015), der Vorhersage physiologischen Stresses (Parent et al., 2019), der Klassifizierung (Choi et al., 2019), der Erkennung von Parkinson (Vasquez-Correa et al., 2018) und dreidimensionaler Navigation (Barbot et al., 2016).

#### **Für den Spitzensport bedeutet das:**

Die Verwendung multimodaler Daten kann dazu beitragen, Schwächen einzelner Sensoren mit anderen Sensoren abzudecken und somit eine robustere Wahrnehmung zu ermöglichen. Die Kombination von mehreren Sensormodalitäten (sensor fusion) kann auch im Spitzensport zu genaueren Messungen (und somit auch genaueren Vorhersagemodellen) führen.

## 3.2 M: Modellierung, Lernen und Vorhersage

In diesem Abschnitt setzen wir uns mit dem Modellierungsschritt **M** von KI-Systemen auseinander. Dieser Schritt wird häufig in Verbindung mit **S** und/oder **P** betrachtet, da die reine Wahrnehmung und Sensorik an sich nur Daten liefern, welche noch verarbeitet werden müssen, um sie in eine für das KI-System nützliche Form zu bringen. Zwischen **S**, **M** und **P** befinden sich in Forschung und Anwendung häufig Verflechtungen, welche nicht immer konsequent getrennt betrachtet und evaluiert werden. Es wäre hier nicht zielführend, zu versuchen, die gesamte Forschung in diesem Bereich darzustellen. Stattdessen beleuchten wir einige besonders herausragende Entwicklungen, auch für Anwendungsbereiche, in denen

keine großen Datenmengen zur Verfügung stehen und Methoden, welche besonderes Potenzial zum Transfer in den Spitzensport besitzen. Außerdem betrachten wir gesondert die Themen, welche einen wichtigen Bezug zum Spitzensport aufweisen.

### 3.2.1 Deep Learning

Die vielleicht größten Entwicklungssprünge der letzten 10 Jahre sind bei der Entwicklung von lernenden Modellen zu beobachten, welche in der Lage sind, auf Basis großer Datenmengen zu lernen. Diese Datenmengen, auch Big Data genannt, die im Rahmen der Digitalisierung entstanden sind bzw. entstehen, erlauben es, wesentlich komplexere Modelle zu lernen. Die betreffenden Lern- und Modellierungstechniken werden mit dem Begriff „Deep Learning“ (DL) bezeichnet. Sie basieren auf klassischen Methoden künstlich neuronaler Netze. Im Deep Learning sind diese Netze sehr komplex bzw. tief. Es gibt viele Modellierungsschichten, die unterschiedliche mathematische und funktionale Aufgaben übernehmen. Beispielsweise können die Schichten am Anfang des Modells dafür gedacht sein, anhand von Bilddaten einfache Bildeigenschaften wie Kanten und Ecken zu extrahieren. Erst die späteren Schichten fassen diese Merkmale dann wieder in komplexere Darstellungen zusammen. Aus vielen Kanten lassen sich nun Formen erkennen, d. h. lernen. Die Einteilung der Aufgaben pro Schicht erfolgt aber auf automatische Weise – somit müssen die Entwickler der Modelle sich nicht mit deren Details auseinandersetzen (Goodfellow et al., 2016).

Die Komplexität der Deep Learning Modelle setzt voraus, dass entsprechend viele Daten zum Training der Modelle zur Verfügung stehen. Betrachtet man die letzten zehn Jahre, dann findet man zahlreiche Beispiele für eine erfolgreiche Anwendung von Deep Learning Modellen (Das et al., 2017; Litjens et al., 2017; Kamilaris et al., 2018). Bei der Frage, welche Modellierungsmethode im Teilschritt M „Modellierung, Lernen und Vorhersage“ (s. Kap. 2) zu wählen ist, sollten auch die Methoden des Deep Learnings in Betracht gezogen werden, jedoch unter Einbeziehung der bislang vorliegenden Erfahrungen (Litjens et al., 2017). Für den Bereich der medizinischen Datenverarbeitung stellen Litjens et al. (2017) fest,



dass die Ergebnisse keineswegs immer erfolgreich waren. Häufig sind für die Analyse aufgrund der Aufgaben, der Sicherheitsanforderungen (sowohl im Sinne von safety als auch security) und der Komplexität der Daten weiterhin menschliche Experten unabdingbar, insbesondere für die letzte Sichtung und Entscheidung.

Eine besondere Modellgruppe sind die sogenannten unsupervised Lern-Methoden, also die Erstellung von Klassifikationen und Abbildungen auf Basis ungelabelter Daten. Solche Methoden wie variational autoencoders und generative adversarial networks sind besonders für die Daten(vor)verarbeitung bei großen Datenmengen geeignet, wenn keine Klassifikationsdaten vorhanden sind. Für die Anwendung im Kontext des Spitzensports sollten folgende Fragen bzgl. der Datenlage getrennt betrachtet werden: Wie viele Daten stehen zur Verfügung? Wie viele Daten können in eine Zielfunktion wie ein Klassifikationslabel gegeben werden und wie viele Daten liegen nur im „Rohformat“ vor? Abgesehen von der Anwendung im medizinischen Sektor bieten sich derartige Methoden z. B. auch auf dem Gebiet der Landwirtschaft an (Kamilaris et al., 2018). Hier ist Deep Learning in vielen Fällen den klassischen Methoden zu bevorzugen, nicht zuletzt, weil die Menge der Daten durch die industrielle Landwirtschaft sehr groß und relativ einfach zu erweitern ist. Somit können Medizin und Landwirtschaft bzgl. der Verfügbarkeit von Daten als die beiden Extrema eines Kontinuums von „klein“ zu „groß“ angesehen werden.

#### **Für den Spitzensport bedeutet das:**

Für jedes Projekt im Spitzensport muss gesondert festgestellt werden, welche Daten vorliegen und welche Methoden des maschinellen Lernens anwendbar sind. Bei der Beurteilung der Daten ist in erster Linie die Datenmenge und die Datenqualität in den Blick zu nehmen (Welche Zielwerte wie z. B. Klassifikationsdaten sind enthalten?).

Die Erkennung von Aktivitäten aus Sensordaten, sogenannten Wearables, unter Hilfestellung von Deep Learning wurde in einem aktuellen Surveypaper besprochen (Wang et al., 2019). Die

Autoren stellen fest, dass Deep Learning hier einige Schwächen klassischer Methoden überwinden und die Modellierung stark vereinfachen kann. Verantwortlich hierfür ist die Möglichkeit, große Mengen ungelabelter Daten mit Unsupervised Learning in klassische Modelle „einzuschleusen“, indem zuvor entsprechende Labels für die Daten gelernt werden. Der genannte Artikel zeigt die Möglichkeiten des Deep Learnings in Kombination mit Wearables auf, allerdings gibt es noch spezifische Probleme, die gelöst werden müssen. Die Modelle sind noch nicht vollständig mobil und online verwendbar und brauchen aufgrund der Rechenintensität häufig eine Verbindung zu einem leistungsstarken Dienstleistungsanbieter. Auch ist zu betonen, dass obwohl Unsupervised Learning bei unqualifizierten Daten hilfreich sein kann, immer noch qualifizierte Daten benötigt werden, um die Modelle in einen nutzbaren Zustand zu bringen.

**Für den Spitzensport bedeutet das:**

Die Modellierung von Daten aus Wearables kann durch Deep Learning unterstützt werden. Die spezifischen Probleme, die vor allem die Portabilität der Modelle (Training und Vorhersage) reduzieren, müssen technisch oder methodisch abgefangen werden.

Bei großen Mengen an unqualifizierten Daten sollten in Forschungsprojekten Methoden des Unsupervised Learning daraufhin untersucht werden, ob diese auch im Bereich der Sportdaten eingesetzt werden können.

Die Verfügbarkeit von Modellierungsmethoden steht und fällt häufig mit den Kosten und hängt von Lizenzmodellen ab. Hierzu sei auf die in Pouyanfar et al. (2018) erwähnten Open Source Modelle verwiesen sowie auf Programmiersprachen, welche auch die Integration leistungsstarker Grafikprozessoren (GPUs) unterstützen. Die Verwendung von Open Source Software ist nicht nur aufgrund der geringeren Kosten wichtig, ein Großteil aller Machine Learning Experten arbeiten ausschließlich mit Open Source Software. Der Zugang sowohl zu qualifiziertem Personal als auch zu

aktuellen Algorithmen- oder umfangreichen Programmbibliotheken wird durch die Verwendung von Open Source Software begünstigt.

**Für den Spitzensport bedeutet das:**

Die Verwendung proprietärer Modellierungsmethoden sollte vermieden werden. Die aktuellen und leistungsstarken Deep Learning Modellierungsmethoden benutzen offene Lizenzierungsmodelle. Es sollte, wann immer möglich, auf freie Open Source Software zurückgegriffen werden.

Sensorgestützte Aktivitätserkennung hat zum Ziel, menschliche Aktivitäten aus einer Vielzahl von Rohdaten/Sensorwerten zu erkennen. Konventionelle Methoden beruhen dabei häufig auf heuristischer (manueller) Merkmalsextraktion, was die Generalisierungsleistung reduzieren kann. Auf Deep Learning basierende Methoden sind für die sensorgestützten Aufgaben der Aktivitätserkennung gut geeignet und werden heute in diesem Bereich erfolgreich in den meisten Anwendungsfällen eingesetzt (Wang et al., 2019).

**Für den Spitzensport bedeutet das:**

Die Erkennung von Aktivitäten kann mit Methoden des Deep Learnings erfolgen, wenn größere Datenmengen zur Verfügung stehen.

Die Analyse sogenannter multimodaler Daten aus Signalen mehrerer, unterschiedlicher Sensoren mit Deep Learning Methoden befindet sich erst in den Anfängen (Pouyanfar et al., 2018). Allerdings lassen sich einige Methoden erkennen, mit denen Farb- und Tiefendaten miteinander verschmolzen (sensor fusion) über Deep Learning aufbereitet werden können. Wang et al. (2018a) widmen sich in einem Surveypaper der Erkennung menschlicher Bewegungsabläufe mittels Deep Learning Ansätzen. Die Autoren beschreiben zwar eine große Vielfalt an Methoden, betonen aber gleichzeitig, dass für die Anwendung eine Vielzahl an Problemen noch nicht gelöst sind.

**Für den Spitzensport bedeutet das:**

Die Integration von Daten unterschiedlicher Sensoren mit Hilfe von Deep Learning ist ein aktives Forschungsfeld und bietet neue Möglichkeiten. Dennoch sollten nach wie vor klassische Methoden des Sensor Fusion, wie zum Beispiel Kalman Filter, berücksichtigt werden. Klassische Methoden sind vor allem dann zu bevorzugen, wenn bestimmte Korrelationen und Kausalmechanismen bekannt sind.

Generative Modelle, wie Generative Adversarial Networks (GAN) und Variational Autoencodern (VAE), erlauben es, hochdimensionale Daten auf einen niedrigdimensionaleren Raum zu projizieren. So können Daten mit nur wenigen Parametern beschrieben und in dem vereinfachten Raum nach Problemlösungen gesucht werden. Gleichzeitig können aus den Beobachtungsdaten neue interpolierte Zwischenformen generiert werden. GAN und VAE erlauben auch Erkennung von Anomalien in Daten (z. B. nutzbar für die Erkennung ungewöhnlicher Bewegungen), die Synthese von Bildern und Texten (z. B. nutzbar für das Beschreiben und Erzeugen von Bildern für die Bewegungsanalyse und -synthese) und die Herstellung von Beziehungen aus unterschiedlichen Bilddomänen (möglicherweise nutzbar für Integration und Transfer zwischen unterschiedlichen Sportdomänen) (Kim et al., 2017; Schlegl et al., 2017; Zhang et al., 2017).

Generative Modelle können auch auf Optimierungs- und Planungsergebnisse angewendet werden (Hagg et al., 2020). So können größere Lösungsmengen über eine 2D-Flächenprojektion in eine für den Nutzer anschauliche Form gebracht werden.

**Für den Spitzensport bedeutet das:**

Generative Modelle können dafür verwendet werden, komplexe Datenstrukturen in ein anschaulicheres Format zu übertragen, was eine Interpolation zwischen den Datenpunkten ermöglicht. Solche Modelle können sowohl auf Wahrnehmungsdaten als auch auf Optimierungs- und Planungsergebnisse angewendet werden.

Die Verwendung von generativen Modellen kann für Visualisierungszwecke hochdimensionaler Daten und Optimierungsergebnisse eingesetzt werden. So können Nutzende (z. B. Trainer und Trainerinnen, Sportler und Sportlerinnen usw.) ein besseres Verständnis für die Daten und Ergebnisse entwickeln.

Darüber hinaus können generative Modelle verschiedene Anomalien in den Daten erkennen, eine Synthese von Bildern und Texten herstellen sowie Beziehungen aus unterschiedlichen Bilddomänen identifizieren.

Generative Modelle können z. B. im Training für folgende Zwecke eingesetzt werden: 1) zur Erkennung unüblicher Bewegungen und 2) zur Beschreibung und Erzeugung von Bildern für die Bewegungsanalyse und -synthese sowie 3) den Transfer zwischen unterschiedlichen Sportdomänen.

### 3.2.2 Transferlernen

Das Transferlernen (Lu et al., 2015; Pan et al., 2016) bezieht sich auf Modelle des maschinellen Lernens, die Gelerntes einer Domäne auf eine andere Domäne übertragen. So können zum Beispiel neuronale Modelle auf einem großen Datensatz (viele Personen) vortrainiert werden und danach auf einen anderen Datensatz (eines Individuums) weitertrainiert werden, womit das Problem der kleinen Datenmengen teilweise gelöst werden kann. Die tieferen Schichten in neuronalen Modellen, welche, wie bereits erwähnt, im vortrainierten Stadium z. B. bestimmte einfache Bildeigenschaften gelernt haben, lassen sich in der neuen Domäne weiterverwenden. Im Spitzensport hat die Methode des Transferlernens das Potenzial, in Bereichen, in denen viele Daten zur Verfügung stehen, vortrainiert zu werden und dann auf solche Bereiche transferiert zu werden, in denen nur begrenzte Datenmengen bereitstehen.

#### **Für den Spitzensport bedeutet das:**

Der Transfer von Modellen, die in Bereichen mit einer großen Menge an Daten trainiert wurden, auf datenarme Bereiche, ist

eine vielversprechende Forschungs- und Entwicklungsstoßrichtung.

Für Sportarten, welche keine besonders große Datenmengen zur Verfügung haben, können Modelle z. B. mit Daten aus dem Amateursport vortrainiert und dann in den Spitzensport transferiert werden.

### 3.2.3 Erklärbarkeit (Explainability)

Die zunehmende Abhängigkeit von Algorithmen und Modellen führt in vielen Fällen zu systematischen Verzerrungen und Fehlentscheidungen. Erklärbare KI beschäftigt sich damit, Transparenz und Nachvollziehbarkeit in die Ergebnisse statistischer Black-Box-ML-Verfahren zu bringen, insbesondere betrifft dies den Bereich des Deep Learning (DL). Die Erklärbarkeit von Modellen ist in den letzten fünf Jahren ein zentrales Thema im Forschungsfeld des maschinellen Lernens geworden und erlebt aktuell eine rasante Entwicklung. Vor allem in Bereichen, wo es zu direkten körperlichen und mentalen Auswirkungen auf den Menschen kommt, ist es unumgänglich, die verwendeten Modellierungstechniken, Vorhersagen und Modelle zu verstehen, verständlich zu machen, zu analysieren und Transparenz bezüglich der automatisierten Modellierung und Entscheidung herzustellen.

Erklärbare KI stößt auch in der Medizin auf großes Interesse. Wo klassische KI-Systeme zwar nachvollziehbare Ansätze lieferten, war ihre Schwäche der Umgang mit Unsicherheiten in der realen Welt. Probabilistische Lernverfahren und auch Deep Learning, ist erfolgreicher, aber zunehmend undurchsichtig.

Unter anderem Holzinger et al. (2019) argumentieren, dass es notwendig ist, in der Medizin über die erklärbare KI hinauszugehen. Für erklärbare medizinische Entscheidungen braucht man Kausalität, nicht nur statistische Korrelation. Holzinger et al. (2019) geben definitorische Hinweise zur Unterscheidung zwischen Erklärbarkeit und Kausalität und beschreiben einen Anwendungsfall für erklärbare KI (DL-Interpretation) aus der Histopathologie. Kausalität unterscheidet sich von der Erklärbarkeit dadurch, dass

die Kausalität eine Eigenschaft (in diesem Fall einer Person) ist, während sich die Erklärbarkeit auf die Eigenschaft eines Systems bezieht. Dazu schlagen die Autoren eine Erklärbarkeitsschnittstelle vor, in der das Black Box Modell eingebettet wird. Die Schnittstelle bietet Analysemethoden, welche das Modell proben und testen können.

Weitere Entwicklungen sind unter anderem im Bereich der Modellbildung zu beobachten. Hier wurden in jüngster Zeit Frameworks für erklärbare KI-Systeme (Preece et al., 2018) und für die Bewertung der Erklärbarkeit von KI-Systemen (Sokol et al., 2020) entwickelt. Die Autoren stellen eine Taxonomie und eine Reihe von Deskriptoren vor, die zur Charakterisierung und systematischen Bewertung erklärbarer Systeme entlang von fünf Schlüsseldimensionen verwendet werden: Funktionalität, Operationalität, Benutzerfreundlichkeit, Sicherheit und Validierung.

*„Die Intransparenz, Unabhängigkeit von einem Modell und der Mangel an kausalen Erkenntnissen im Zusammenhang mit Ansätzen des maschinellen Lernens sind nicht unbedingt radikal anders als routinemäßige Aspekte der medizinischen Entscheidungsfindung.“  
(London et al., 2019).*

Menschen und Maschinen wohnt das Problem der Erklärbarkeit inne. In beiden Fällen entscheidet nach unserer Ansicht die Daten- oder eben die Erfahrungslage. Und in beiden Fällen gibt es das Problem der Verwechslung von Korrelation mit Kausalität.

Der Einsatz von Machine Learning (ML) sollte auf spezifische Aufgaben eingeschränkt bleiben, für die die Genauigkeit und Zuverlässigkeit empirisch validiert worden sind. Nur wenn ML die wirksamste Alternative darstellt, kann man diese mit der entsprechenden Validierung einsetzen, selbst dann, wenn die Gründe für eine „bessere“ Leistung intransparent bleiben. Die Robustheit der Systeme sollte während der Entwicklung getestet werden, indem untersucht wird, wann deren Genauigkeit und Zuverlässigkeit nachlassen. Dazu gehörten die Validierung und laufende Neubewertung der Systemleistung auf mehreren, realitätsnahen Datenmengen.

Weitere Überblicksarbeiten zum Thema sind Tjoa et al. (2019), Ribeiro et al. (2016), Lundberg et al. (2017), Adadi et al. (2018) und Rosenfeld et al. (2019).

**Für den Spitzensport bedeutet das:**

Erklärbarkeit von Modellen muss zwingend auch in der Anwendung im Spitzensport Einzug halten. Nur so lassen sich alle betroffenen Gruppen davon überzeugen, dass die Modellvorhersage auch in Zukunft und in unerwarteten Situationen nutzbar bleibt und nicht zu erhöhten Risiken führt. Im Vordergrund sollte daher die Validierung aber auch die laufende Neubewertung der Systemleistung stehen. Lernende Modelle tun eben das: sie lernen und sie passen sich an. Somit muss auch die Systemleistung, die sich anpasst, neu bewertet werden.

Einen interessanten Ansatz stellt die Merkmalsattribution dar, die Zuordnung von Klassenrelevanz zu verschiedenen Orten in einem Bild. Besonders wichtig ist sie im Bereich der Neurowissenschaften, wo genaue mechanistische Verhaltens- oder Krankheitsmodelle die Kenntnis aller Merkmale erfordern, die Personen oder Objekte unterscheiden. Bass et al. (2020) schlagen die Verwendung eines generativen Modells vor, um die Klassenrelevanz explizit von Hintergrundmerkmalen zu entflechten. Damit lassen sich die Interpretierbarkeitseigenschaften verbessern, was zu aussagekräftigen Merkmalskarten führt. Diese Karten lassen sich dann interpretieren und durch menschliche Experten validieren.

**Für den Spitzensport bedeutet das:**

Die Merkmalsattribution in Klassifizierungsaufgaben kann mit Hilfe von generativen Modellen so dargestellt werden, dass sie von Experten analysiert werden können. Dies ist für die Erklärbarkeit von Vorhersagen unumgänglich: wenn der Nutzer oder die Nutzerin weiß, weshalb eine bestimmte Entscheidung gefallen ist, kann er oder sie diese auch hinterfragen.



Die Transparenz und Erklärbarkeit von Modellen des maschinellen Lernens kann auch im Spitzensport mit Hilfe von zum Beispiel generativen Modellen erhöht werden.

### 3.2.4 Robustes Lernen

Robustes Lernen, also das Lernen unter Berücksichtigung fehlerhafter oder verrauschter Daten, wird in der Bilddomäne des medizinischen Bereichs auch für kleinere Datenmengen eingesetzt. Die Datenverfügbarkeit spielt hierbei eine entscheidende Rolle für die Leistungsfähigkeit von Systemen des Deep Learnings. Diese Herausforderung ist besonders akut im Bereich medizinischer Bilder, insbesondere in der Pathologie. Zwei Faktoren sind hier insbesondere zu nennen: 1) begrenzte Anzahl von Fällen und 2) große Unterschiede am Standort, im Maßstab und im Aussehen. Künstlich generierte Daten können hier hilfreich sein. Die Augmentation eines Datensatzes mit künstlich erzeugten Lungenknoten kann beispielsweise die Robustheit von Modellen für die pathologische Lungensegmentierung von CT-Scans verbessern (Jin et al., 2018). Die Methode braucht nur 1000 Datensätze und verwendet ein generatives Modell dazu, um simulierte Trainingsbilder für besonders schwierige Datensätze zu erzeugen.

#### **Für den Spitzensport bedeutet das:**

Das Lernen von Modellen, die robust sind bzgl. fehlerhaften oder komplexen Daten kann durch das Generieren von künstlichen Daten erleichtert werden.

In solchen Fällen, in denen Daten aus dem Spitzensportbereich verrauscht oder fehlerhaft sind, können trotzdem robuste Modelle auch auf Basis eingeschränkter Datenmengen trainiert werden, indem künstlich Daten mit generativen Modellen erzeugt werden.

### 3.2.5 Statistische („Grey-Box“) Modellierungsmethoden

Beim Großteil der Methoden des Deep Learnings sind Modelle nicht transparent (können nicht verstanden werden). Es handelt sich bei den Modellen um sogenannten Black-Box Modelle. Im Gegensatz dazu wird häufig auf statistische Modelle zurückgegriffen, welche in der Lage sind, nicht nur eine Vorhersage zu treffen, sondern auch die Modellkonfidenz und eine Einschätzung von Rauschwerten in den Daten zu geben („Grey-Box“ Modelle). Hier lässt sich vor allem Gaußprozessregression (GP) als Modellierungsmethode verwenden (Rasmussen et al., 2003; Vanhatalo et al., 2013). Gaußprozesse lernen keine Funktion, sondern eine meist normalverteilte statistische Distribution von Funktionen. Die Varianz der Modelle wird zur Modellkonfidenz hinzugezogen.

#### **Für den Spitzensport bedeutet das:**

Statistische Modelle können im Gegensatz zu den meisten Machine Learning Methoden nicht nur eine Vorhersage, sondern auch direkt eine Modellkonfidenz geben.

Bei der Vorhersage sollte die Verwendung statistischer, „Grey-Box“ Modelle, wie Gaußprozessregressionsmodelle, immer als Alternative untersucht werden. Konfidenzintervalle über die Vorhersage können die Aussagekraft von Modellen unterstützen und relativieren. Vor allem in Grenzfällen sollte die Modellkonfidenz für die Risikovermeidung immer berücksichtigt werden.

Die ursprüngliche Formulierung von GP war nicht in der Lage mit mehr als rund 1000 Datenpunkten umzugehen. In den letzten Jahren sind aber Methoden entstanden, welche dies sehr wohl erlauben und somit sind GP auch immer mehr für Big Data (Liu et al., 2018; van Stein et al., 2015) geeignet.

#### **Für den Spitzensport bedeutet das:**

Gaußprozessregressionsmodelle können auch auf größeren Datenmengen trainiert werden. Auch bei Sportarten mit größeren

Datenmengen können Gaußprozessregressionsmodelle eingesetzt werden.

### 3.2.6 Fehler- und Risikoerkennung

Fehler- und Risikoerkennung scheint im Spitzensport längst Einzug gehalten zu haben. Eine groß angelegte Studie zur Verletzungsrisikoeinschätzung analysierte 58 Studien, wobei 11 KI-Techniken oder -Methoden in 12 Mannschaftssportarten angewandt wurden (Claudino et al., 2019). 76% der Teilnehmer und Teilnehmerinnen kamen aus dem Spitzensport. Die am häufigsten verwendeten KI-Techniken oder Methoden waren künstliche neuronale Netzwerke, Entscheidungsbaum-Klassifikatoren, Support-Vektor-Maschinen und Markov-Prozesse mit guten Leistungsmetriken. Fußball, Basketball, Handball und Volleyball waren die Mannschaftssportarten, in denen KI häufiger angewendet wurde.

#### **Für den Spitzensport bedeutet das:**

Die Fehler- und Risikoanalyse gehört zum sportwissenschaftlichen Alltag.

### 3.2.7 Verarbeitung menschlicher Sprache

Die Verarbeitung menschlicher Sprache ist einer der ältesten Forschungsbereiche innerhalb der KI-Forschung. Hier gibt es folgende Kategorien zu unterscheiden: Informationsextraktion, Übersetzung, Sprache zu Text, Text zu Sprache und Textgenerierung. Die Systeme sind heute sehr gut in der Lage, zu übersetzen und Sprache in Text und vice versa umzuwandeln. In der Sportdomäne wurden im vorletzten Jahrzehnt Methoden entwickelt für unter anderem Keywordgenerierung (Xu et al., 2004), Realzeitspracherkennung (Ariki et al., 2003), Ereignisdetektion (Xu et al., 2003a; Xu et al., 2003b; Baillie et al., 2003; Li et al., 2001), Aktionserkennung (Zhu et al., 2006) und automatisiertes Labelling (Chambers et al., 2004).

**Für den Spitzensport bedeutet das:**

Sprachinterfaces sind heute in der Industrie angekommen und finden eine weit verbreitete Verwendung. Sie lassen sich deshalb problemlos auch in Spitzensportprojekten einsetzen.

Sprachinterfaces sind durch die Entwicklungssprünge der letzten zehn Jahre auch im Spitzensport längst angekommen.

### 3.2.8 Verteiltes Lernen (Federated Learning)

Federated Learning (FL) besteht darin, Modelle auf der Grundlage von Datensätzen zu erstellen, die über mehrere Geräte verteilt sind und gleichzeitig Datenlecks verhindern. Jüngste Verbesserungen konzentrieren sich auf die Bewältigung der statistischen Herausforderungen und die Verbesserung der Sicherheit beim FL. Es gibt auch Forschungsbemühungen, FL personalisierbarer zu machen. FL findet häufig auf der Basis von verteilten Interaktionen zwischen mobilen Anwendern und Anwenderinnen statt. Herausforderungen sind aktuell die hohen Kommunikationskosten bei massiver Verteilung, eine unausgewogene Datenverteilung und die Gerätezuverlässigkeit. Darüber hinaus werden die Daten nach Benutzer- oder Geräte-Nummern, also horizontal im Datenraum, partitioniert.

Hauptkritikpunkt bei der Anwendung des FL im Spitzensport ist die Datensicherheit, also wie konkret die Verhinderung von Datenlecks umgesetzt wird. Zwar können auf Basis der zur Verfügung stehenden Datenmenge auch komplexere Modelle trainiert werden, dabei besteht die Datenbasis allerdings aus den Daten von Einzelsporttreibenden oder Teams, die in Konkurrenz stehen. Hier gibt es Bemühungen, um den Datenschutz und die Datensicherheit zu bewahren bzw. zu gewähren (Yang et al., 2019).

**Für den Spitzensport bedeutet das:**

Federated Learning (FL) kann bei dem Problem von stark verteilten Daten eine Lösungsmethode darstellen, um komplexere Modelle zu trainieren. Allerdings ist auf den Datenschutz und die Datensicherheit zu achten.

Durch pseudonymisiertes oder anonymisiertes FL könnten komplexere Modelle für die Unterstützung des Spitzensports verfügbar werden. Dies ist insbesondere im Kontext von mobilen Geräten relevant.

### 3.2.9 Automatisiertes vs. augmentiertes Lernen

Beim Lernen von Modellen besteht häufig die Schwierigkeit, die richtigen Modellkonfigurationsparameter zu bestimmen. Hierbei wird vom Anwender eine Expertise benötigt, welche nicht immer gegeben ist. Um die Zugänglichkeit zum maschinellen Lernen auch für Nicht-Experten zu erhöhen, wird versucht, diese Konfiguration automatisch durchzuführen. Hier lassen sich folgende Arbeitsschritte, die zu automatisieren sind, unterscheiden (He et al., 2021):

1. Datenaufbereitung/-aufnahme (aus Rohdaten und verschiedenen Formaten),
2. Aufgabenerkennung (z. B. binäre Klassifikation, Regression, Clustering oder Ranking),
3. Feature-Engineering,
4. Auswahl des Modells,
5. Hyperparameter-Optimierung des Lernalgorithmus und der Features,
6. Pipeline-Auswahl unter Zeit-, Speicher- und Komplexitätsbeschränkungen,
7. Auswahl von Evaluationsmetriken und Validierungsverfahren,
8. Problemprüfung,
9. Analyse der erzielten Ergebnisse und die Erzeugung von Benutzerschnittstellen und Visualisierungen.

Für den Nutzen von automatisiertem Lernen (AutoML) ist die Evidenzlage beschränkt. Es existieren zwar viele Ansätze und auch offene Frameworks, aber es gibt wenig Vergleiche in der realen Welt zwischen AutoML und zum Beispiel augmentiertem Lernen. Insgesamt ist die Zugänglichkeit zu Techniken des maschinellen

Lernens differenziert zu betrachten. Wenn auch Nicht-Experten und Nicht-Expertinnen der Zugang erleichtert wird, diese aber nicht einschätzen können, ob ein Modell richtig trainiert wurde, kann der Versuch, KI in den Spitzensport zu integrieren, scheitern.

**Für den Spitzensport bedeutet das:**

Automatisiertes Lernen (AutoML) bietet Potenzial beim Einsatz im Spitzensport, da die Methodik die Zugänglichkeit zu ML erhöht. Wenn allerdings Nicht-Experten und Nicht-Expertinnen ML-Modelle verwenden, kann es leicht zu Fehlinterpretationen der Ergebnisse kommen.

Es ist zu empfehlen, dass immer ein Experte und Expertin in die Anwendung involviert ist und auch die Evaluierung automatisierter Methoden der Modellfindung im Nachgang mit Hilfe von Experten und Expertinnen durchgeführt wird.

### 3.2.10 Small Data

In vielen Bereichen der KI-Anwendung werden Methoden eingesetzt, die Big Data verwenden. Allerdings gibt es eine Vielzahl an Einsatzszenarien, wo die erforderlichen Datenmengen entweder nicht vorliegen oder aufgrund des Settings hierüber keine befriedigenden Lösungen zu erzielen sind, wie zum Beispiel in der personalisierten Medizin oder individualisierten Trainingssteuerung im Spitzensport. Ein rigoroses, komplementäres Small-Data-Paradigma, welches sowohl autonom von und im Zusammenspiel mit großen Datenmengen funktioniert, wird ebenfalls benötigt (Hekler et al., 2019). Oft, und vor allem in einigen Bereichen des Spitzensports, stehen keine großen Datenmengen zur Verfügung. Außerdem kann man basierend auf kleinen Datenmengen agileres Lernen ermöglichen. Nicht zuletzt sind kleine Datenmengen als komplementär zu „Big Data“ zu sehen. Manche Phänomene im Spitzensport (z. B. Trainingsanpassungen) könnten zunächst über viele Personen „modelliert“ werden, anschließend lassen sich die Modelle über weitere Modellierungsschritte individuell anpassen.

### *Allgemeine Hinweise*

Eine kleine Stichprobe hoher Qualität kann unter bestimmten Umständen und in Abhängigkeit der Zielstellung bessere Rückschlüsse geben als eine große Stichprobe geringer Qualität. Grundsätzlich verursachen die Datenerfassung und -auswertung sowie der Schutz der Privatsphäre Kosten, so dass diese immer gegen den Nutzen abgewogen werden sollten. Zur (nach)kalibrierten Vorhersage kann in vielen Fällen die Aggregation kleiner Datensätze auf individueller Ebene besser sein als die Ansammlung großer, wenig personalisierter Datenmengen (Faraway et al., 2018).

#### **Für den Spitzensport bedeutet das:**

Daten zu sammeln ist per se kein Ziel. Die Kosten für die Erfassung, die Auswertung und den Schutz der Privatsphäre können dazu beitragen, dass nur mit Small Data gearbeitet werden kann. Bei der Entwicklung von Methoden und Anwendungen im Spitzensportbereich sollte auf die immer größer werdende Relevanz von Methoden und Techniken für kleine individuelle Datenmengen geachtet werden, welche insbesondere die Privatsphäre berücksichtigen.

Es kann in manchen Fällen sinnvoll sein, Daten miteinander zu teilen. Ferguson et al. (2014) prüfen die Frage der gemeinsamen Nutzung von vielfältigen und heterogenen kleinen Datensätzen, die von einzelnen Neurowissenschaftlern produziert werden, sogenannte Long-Tail-Daten.

Durch die gemeinsame Nutzung können über die Aggregation und das Mining diverser Long-Tail-Daten zahlreiche kleine Datenquellen zu Big Data konvertiert werden. Die Autoren definieren Best Practices zur gemeinsamen Nutzung von Long-Tail-Daten:

Sichtbarkeit	Daten müssen so modelliert und gehostet werden, dass sie auffindbar sind.
Zugänglichkeit	Wenn Daten gefunden werden, müssen sie abgefragt werden können.
Verständlichkeit	Daten können sowohl von Menschen als auch Maschinen gelesen und verstanden werden.
Beurteilbarkeit	Die Zuverlässigkeit der Datenquellen kann bewertet werden.
Nutzbarkeit	Autoren und Autorinnen sollten sicherstellen, dass die Daten nutzbar sind.

Wichtig für die KI im Bereich der Small Data ist die Entwicklung neuer Dateninfrastrukturen, die kleine Daten zusammenfassen, skalieren und miteinander verknüpfen, um größere Datensätze zu erstellen. Damit lässt sich die gemeinsame Nutzung und Wiederverwendung fördern, um – auch in Kombination mit großen Daten (Big Data) – die Analyse mit Hilfe von Analysemethoden für große Datenmengen zu ermöglichen (Kitchin et al., 2015).

#### **Für den Spitzensport bedeutet das:**

Die gemeinsame Nutzung von kleinen Datensätzen, sogenannte Long-Tail-Daten, kann es ermöglichen, Big Data Ansätze anzuwenden. Hierfür sollten Best Practices zur Sichtbarkeit, Zugänglichkeit, Verständlichkeit, Beurteilbarkeit und Brauchbarkeit der Daten eingehalten werden.

In verschiedenen Bereichen des Spitzensports (z. B. einzelne Sportarten/Disziplinen oder Trainingsgruppen), in denen nur Small Data zur Verfügung stehen, könnten die Daten durch Vereinheitlichung in der Datenstruktur zu größeren Datensätzen verknüpft werden. Somit können dann auch Lernmethoden eingesetzt werden, welche größere Datensätze benötigen. Auch hier ist selbstverständlich auf die Datensicherheit und Privatsphäre im Rahmen der Konkurrenzgedanken im Sport zu achten.



## Methoden

Es gibt Hinweise darauf, dass auch Big Data bzw. Deep Learning Methoden in manchen Fällen auf kleineren Datensätzen anwendbar sind. Olson et al. (2018) zeigen, dass bei kleinen Benchmarkdatensätzen auch Deep Learning Methoden nutzbringend eingesetzt werden können, indem große neuronale Netze in kleinere Netze umgewandelt werden und sich hierdurch eine Art Random Forest erzeugen lässt. Es wird gezeigt, dass bei einer Sammlung aus 116 realen Datensätzen kein sogenanntes Overfitting stattfindet. Allerdings handelt es sich hier um erste Evidenzen.

Für die Vorhersage biomedizinischer Ergebnisse auf der Grundlage sehr kleiner Datensätze (unter 100 Datenpunkte) mittels Klassifizierungs- und Regressionsaufgaben werden neuartige Techniken vorgeschlagen, bei denen für die Modellentwicklung und die Modellvalidierung anhand von Surrogatdaten mehrere Durchläufe hintereinandergeschaltet werden (Shaikhina et al., 2015).

Auch gibt es neue Methoden, die spezifisch für kleinere Datenmengen entwickelt werden. Abgesehen von den klassischen Methoden aus dem „altmodischen“ Machine Learning (good old fashioned AI), welche immer noch breite Verwendung finden, gibt es tiefe Netzwerke, die bei Aufgaben mit geringen Datenmengen eine hervorragende Leistung zeigen und weitreichend getunte Versionen klassischer Methoden wie Random Forests schlagen (Arora et al., 2019).

Für Datensätze, die überwiegend unausgewogen sind, d. h. die relative Anzahl der zu detektierenden Instanzen einer Klasse ist gering, kann mit einem adaptiven Boosting-Algorithmus eine optimierte Stichprobentechnik etabliert werden (Martin-Diaz et al., 2016). Auch Transferlernansätze können hier hilfreich sein (wie bereits vorab detailliert erläutert wurde). Erfolgreiche Anwendungsfälle finden sich z. B. beim Screening in der Produktion elektronischer Bauteile (Cubuk et al., 2019) oder in der Thermochemie (Grambow et al., 2019).

### **Für den Spitzensport bedeutet das:**

Es werden auch heute noch Methoden für das Lernen von Mustern aus Small Data entwickelt, wobei manchmal auch Big Data

Ansätze anwendbar gemacht werden können. Auch Surrogate und Transferlernen können hier eine Rolle spielen.

Die Ansätze, die für Small Data entwickelt werden, z. B. Surrogate, Transferlernen und spezifische „Small Data Modelle“, aber auch klassische Methoden des maschinellen Lernens, führen zu unterschiedlichen Strategien für den Umgang mit Small Data. Hier ist ein breiter Blick auf die unterschiedlichen Ansätze notwendig, da diese sich in den Anforderungen voneinander unterscheiden.

### 3.2.11 Dedizierte Hardware

Zu den Hardware-Plattformen, die eine für Deep Learning optimierte Beschleunigung darstellen, gehören GPUs (Grafikbeschleunigungskarten) und dedizierte Hardware (ASIC/FPGA). GPUs, die heutzutage einen sehr hohen Rechendurchsatz bei Deep Learning Methoden ermöglichen (Parvat et al., 2017; Mittal et al., 2019) sind zumeist dafür gedacht, auf festen Rechnern oder Laptops installiert zu werden. Durch den geringeren Stromverbrauch können bestimmte gelernte Modelle auf dedizierter Hardware einen Kompromiss zwischen Portabilität, Effizienz und Genauigkeit darstellen (Wang et al., 2018b).

#### **Für den Spitzensport bedeutet das:**

Es kann auch für rechnerisch aufwändigere Methoden auf GPUs oder dedizierte Hardware gesetzt werden. Hier sind der Stromverbrauch und die Portabilität abzuwägen.

## 3.3 P: Planung, Strategie und Optimierung

Die Lösung von Planungs- und Optimierungsproblemen – häufig einfach auch als Optimierungsproblem bezeichnet – kann als eigenständiges Forschungsfeld betrachtet werden, welches in den ver-

schiedensten Domänen seine Anwendung findet. Da die Methoden aus der Optimierung insbesondere für die Konstruktion einer vollständigen KI zwingend notwendig sind, werden in den folgenden Abschnitten jene Optimierungsmethoden kurz beschrieben, die vor allem im Kontext des Spitzensports angewendet werden könnten.

### 3.3.1 Integration der Teilschritte S, M und P (direkte Verknüpfung)

Eine der interessantesten Entwicklungen für ausgewählte Anwendungsbereiche im Spitzensport ist das unmittelbar auf Bildpunkte basierende Lernen von Bewegungsmodellen. Im Mittelpunkt der bildbasierten Analyse steht das Erlernen von dynamischen Modellen, welche hinreichend genau für die Planung sind. Das sogenannte Deep Planning Network (PlaNet) ist ein rein modellbasierter Agent, der die Umgebungsdynamik aus Bildern lernt und Aktionen durch schnelle Online-Planung im latenten Raum auswählt. Der Agent löst ausschließlich auf Basis beobachteter Bildpunkte kontinuierliche Regelaufgaben mit Kontaktdynamik, partieller Beobachtbarkeit und spärlichen Belohnungen und überwindet damit Probleme bisheriger Modelle bzw. Ansätze (Hafner et al., 2018).

#### **Für den Spitzensport bedeutet das:**

Die Planung kann in manchen Fällen direkt auf Rohdaten ausgeführt werden.

Für Sportarten, welche nicht über die finanziellen Möglichkeiten verfügen, größere Projekte zu unterstützen und/oder größere Softwareprodukte zu kaufen, könnten solche Ansätze, die S, M und P direkt miteinander verknüpfen, eine Lösung darbieten.

### 3.3.2 Lösungsdiversität

Quality Diversity (Lösungsdiversität) Algorithmen suchen nach mehreren verschiedenen Lösungen mit ähnlicher Lösungsgüte (Cully et al., 2015). Da die Lösungen der zu optimierenden Probleme meist in hochdimensionalen Parametertupeln kodiert sind, werden

diese zunächst in einem niedrig-dimensionalen Eigenschaftsraum gespeichert. Dieser Raum wird durch wenige Eigenschaften definiert, welche hinsichtlich der Lösungen auf verhaltensbezogenen, morphologischen oder anderen Aspekten beruhen können. Die Aspektwerte der Eigenschaftsdeskriptoren werden berechnet und in eine endliche Zahl an Nischen eingeteilt (dies geschieht üblicherweise durch Diskretisierung des Aspektraums). Lösungen, die dieselbe Nische besetzen, konkurrieren darum, in einem Archiv von Nischen positioniert zu werden. Das Archiv wird zum Vergleich neuer Lösungen verwendet und stellt das Endergebnis des Algorithmus dar. Die Vielfalt an Lösungen, die alle jeweils, in ihrer Nische, bestmögliche Lösungen repräsentieren, ist wichtig, damit Benutzer einen Überblick über die Eigenschaften optimaler Lösungen erhalten können. Übertragen auf den Spitzensport könnte man eine bestimmte Anzahl „optimierter“ Trainingspläne generieren, diese bewerten und anschließend eine Auswahl für die Umsetzung treffen. Auf diese Weise wird dem Benutzenden ein Entscheidungsspielraum eingeräumt, sodass dieser einem Algorithmus nicht „blind“ vertrauen muss. Quality Diversity wurde bisher unter anderem in der Planung von Bewegungsabläufen in der Robotik, aerodynamische Formoptimierung und städtische Planung eingesetzt (Cully et al., 2015; Gaier et al., 2017a; Gaier et al., 2017b; Hagg et al., 2018; Hagg et al., 2019; Urquhart et al., 2018).

**Für den Spitzensport bedeutet das:**

Optimierungsalgorithmen sind immer mehr dazu in der Lage, dem Nutzenden viele verschiedene Lösungen anzubieten, sodass dieser den potenziellen Lösungsraum besser einschätzen und einschränken kann. Die Entscheidung über die finale Lösung bleibt dem Nutzenden selbst überlassen.

Die Akzeptanz von KI-Methoden kann durch das Finden eines vielfältigen Lösungsangebotes erhöht werden, sofern dieses gut dargestellt werden kann.

### 3.3.3 Multiple Kriterien

Für die Optimierung von mehr als nur einem einzigen Kriterium sind im aktuellen Forschungsstand nur kleinere Entwicklungen zu konstatieren. Zur Erlangung des Optimierungsziels müssen Kompromisse zwischen den einzelnen Kriterien im Rahmen einer sogenannten Pareto-Front gefunden werden. Es ist anzumerken, dass neuere, effektivere Versionen solcher Algorithmen wie zum Beispiel das Non-dominated Sorting Genetic Algorithm in der Version 3 verfügbar sind (Deb et al., 2013), die eine höhere Lösungsdiversität ermöglichen. Zudem gibt es insbesondere bei der Optimierung von mehr als drei Kriterien (auch „many objective optimization“ genannt) neuartige Entwicklungen (Li et al., 2015).

#### **Für den Spitzensport bedeutet das:**

Die Optimierung von mehreren Kriterien gehört zu den Standardmethoden, die es zu berücksichtigen gilt.

Die Verknüpfung mehrerer Kriterien, wie z. B. Leistung und Zeiteffizienz, kann durch Optimierungsmethoden berücksichtigt werden. So können Lösungen wie beispielsweise Trainingspläne in Form von sogenannten Trade-Offs dargestellt werden, was die Interaktion zwischen KI und Trainer und Trainerinnen/Sportler und Sportlerinnen unterstützt und damit die Akzeptanz des KI-Einsatzes erhöht.

### 3.3.4 Effiziente Optimierung

Bei der Optimierung mit rechnerisch teuren Auswertungs- oder Kriterienfunktionen werden Lernverfahren aus der Bayes'schen Statistik eingesetzt. Hierbei wird die Idee verfolgt, dass nur bestimmte Lösungen ausgewertet werden, mit denen ein einfaches statistisches Ersatzmodell (Surrogate Model) trainiert werden kann. Diese Ersatzmodelle ersetzen einen Großteil der kostenintensiven Funktionsevaluationen und werden immer wieder mit ausgewählten Lösungen aktualisiert. Die Auswahl der zu evaluierenden Lösungen erfolgt anhand der modellseitig vorhergesagten Lösungs-

potenziale, wobei hierzu das Konfidenzintervall des Modells in Kombination mit der vorhergesagten Lösungsgüte verwendet wird. Durch Kombination der Vorhersage und Konfidenz entsteht eine „optimistische“ Vorhersage, welche nachweislich zu einem effizienten Sampling führt (Jin et al., 2011; Shahriari et al., 2015). Bayes'sche Optimierung wurde auch im Kontext von Multikriterienoptimierung (Emmerich et al., 2016) und Quality Diversity eingesetzt (Gaier et al., 2017a).

#### **Für den Spitzensport bedeutet das:**

Bayes'sche Optimierung führt zu einem deutlichen Effizienzgewinn und sollte bei der Optimierung rechnerisch teurer Probleme eingesetzt werden.

Dateneffiziente online Optimierung kann mit Hilfe von surrogatbasierten Methoden eine potenziell neuartige Interaktion zwischen KI und Sportler und Sportlerin ermöglichen. Mithilfe der so entstehenden Interaktionsschleife können Modelle schnell individualisiert werden, indem die KI konkrete Vorschläge zur Optimierung macht. Bezogen auf das Anwendungsbeispiel Trainingssteuerung (vgl. Kap. 5.1) entsteht so eine Rückkopplungsschleife, in der die Trainingsdaten und -ergebnisse zurück in das Modell geführt werden können. Auf diese Weise kann die Trainingspraxis mit der KI zusammen eine bestmögliche Strategie entwickeln.

### **3.3.5 Robuste Optimierung**

Im letzten Jahrzehnt wurden viele Methoden für die robuste Optimierung entwickelt (Gabrel et al., 2014; Bertsimas et al., 2018). Mit diesen Methoden wird das Ziel verfolgt, Lösungen für jene Problemstellungen zu finden, welche sich durch ein hohes Rauschen in den observierten Daten auszeichnen. Beispielsweise werden neuartige Methoden generativer Modelle dazu verwendet, um Versuchspläne für Produktions- und Logistiksysteme zu optimieren. In einem kompetitiven, rundenbasierten Spiel, versuchen zwei solche Modelle möglichst robuste Lösungen zu erarbeiten (Bergmann et al., 2020).

**Für den Spitzensport bedeutet das:**

Die robuste Optimierung setzt sich zum Ziel, Lösungen für jene Problemstellungen zu finden, welche sich durch ein hohes Rauschen in den observierten Daten auszeichnen.

Da Datenrauschen im Spitzensport in Form von unterschiedlicher Tagesform, unterschiedlichen Beeinflussungsfaktoren bei der Herzfrequenzmessung oder ähnliches sehr häufig auftreten kann, ist die Robustheit von Optimierungslösungen ein wichtiger Faktor und sollte immer in Betracht gezogen werden.

### 3.3.6 Reinforcement Learning

Beim Reinforcement Learning werden KI-Modelle trainiert, die eine Aufgabe möglichst eigenständig lösen sollen. Diese Methodik erregt auch in den nicht-fachspezifischen Medien viel Aufsehen, unterliegt derzeit jedoch noch vielen Grenzen, sodass eine unmittelbare Anwendung im Rahmen des Spitzensports vorerst noch nicht zu sehen ist. In bisherigen Ansätzen wird versucht, KI-Agenten zu trainieren, welche in der Lage sind, z. B. modellfrei Computerspiele zu spielen (Li et al., 2019). Auch wenn die Entwicklung sowie die Übertragung dieser Lösungsansätze auf reale Problemstellungen noch ziemlich am Anfang steht (wenngleich dieser Ansatz bereits in den späten 80er Jahren intensiv „beforscht“ wurde), soll die Kernidee im Folgenden kurz erläutert werden.

Reinforcement Learning (RL) ist ein Bereich des maschinellen Lernens, der sich mit der Frage beschäftigt, wie KI-Agenten in einer Umgebung agieren sollten, um die sogenannte „kumulative Belohnung“ zu maximieren. Diese Belohnung schafft einen Anreiz für die Agenten zu lernen. RL unterscheidet sich vom überwachten Lernen dadurch, dass gekennzeichnete Input/Output-Paare nicht präsent sein müssen und dass suboptimale Aktionen nicht explizit korrigiert werden müssen. Stattdessen liegt der Schwerpunkt darauf, ein Gleichgewicht zwischen der Erforschung von neuen Ansätzen (Erkundung) und der Nutzung von aktuellem Wissen („Ausbeutung“, engl. „exploitation“) zu finden. Hierbei stellt die

Bestimmung eines Gleichgewichtes das grundsätzliche Problem dar, was es in RL zu lösen gilt. In diesem Zusammenhang spielen Bayes'sche Ansätze eine Rolle, weil sie einen eleganten Ansatz zur Handlungsauswahl (Erkundung vs. Ausbeutung) in Abhängigkeit von der Unsicherheit beim Lernen bieten. So kann bereits vorhandenes Vorwissen elegant in die Algorithmen einfließen (Ghavamzadeh et al., 2015).

#### **Für den Spitzensport bedeutet das:**

Innerhalb eines KI-Agenten wird bei der Lösungssuche immer ein Gleichgewicht zwischen Erkundung und Ausbeutung gesucht, welche auch in Abhängigkeit von Unsicherheit in den Eingabedaten, Ausgangszustand und dem Folgezustand in der KI-Schleife zu robusten Lösungen führt.

Die Verwendung einer KI erlaubt es, bei der Optimierung von Plänen und Strategien neuartige Lösungen zu finden. Die Erkundung neuer und die Ausbeutung bewährter Lösungen erlauben es der Spitzensportpraxis, systematisch Chancen und Risiken aufeinander abzustimmen.

## 3.4 I: Intervention, Interaktion und Manipulation

### 3.4.1 Mensch-Maschine-Interaktion

Athleten und Athletinnen verlassen sich auf intrinsische oder extrinsische Rückmeldungen, um ihre sportliche Leistungsfähigkeit zu beurteilen. Unter dem intrinsischen Feedback ist die Information zu verstehen, die aus der Wahrnehmung der eigenen Körperbewegungen und der Position im Raum (d. h. Propriozeption) entsteht, während unter dem augmentierten bzw. dem extrinsischen Feedback die Information zu verstehen ist, die von einem externen Agenten wie beispielsweise der Trainerin oder dem Trainer oder der video-basierten Bewegungsanalyse stammt (Mencarini et al., 2019).



Augmentiertes Feedback ist wichtig für das Lernen und Verbessern, weil es den Sportlern und Sportlerinnen hilft, ihre inneren Empfindungen zu kategorisieren und die Mechanismen, die ihrer Leistung zugrunde liegen, besser zu verstehen. Sportler und Sportlerinnen können diese Art von Feedback während oder nach der Durchführung einer Übung z. B. mit Hilfe sogenannter Wearables erhalten. Ob das Feedback während oder nach der Übung gegeben wird, kann von der Art der Übung und/oder dem Feedback-Inhalt abhängig gemacht werden. Wenn ein Bezug zur Qualität der Bewegung hergestellt werden soll, könnte das Feedback konkrete Kenngrößen der Bewegungsausführung (z. B. biomechanische oder leistungsphysiologische Parameter) beinhalten oder das Bewegungsergebnis, wenn ein Bezug zum erreichten Ziel/Niveau hergestellt werden soll.

Die Rückmeldung in Echtzeit kann je nach Ziel und Zweck visuell, akustisch und/oder haptisch erfolgen. So werden beispielsweise Vibrationen, Töne oder verbale Anweisungen bevorzugt, wenn das Feedback an den Athleten oder die Athletin selbst gerichtet ist und die Bewegungsaktivität von der visuellen Aufmerksamkeit abhängt. Allerdings können haptische oder akustische Informationen auch einem Coach als Feedback mitgeteilt werden, sodass dieser der Athletin oder dem Athleten weitere Anweisungen geben kann. Werden dagegen Informationen an verschiedene Interessengruppen gleichzeitig übermittelt, so können beispielsweise das Publikum, die Trainerschaft, die Teamkollegen oder die Kampfrichter und Kampfrichterinnen über einen visuellen Kanal und die Sportlerin oder der Sportler durch haptische und/oder akustische Reize eine Rückmeldung (Feedback) erhalten. Visuelles Feedback wird aber auch dann verwendet, wenn Sportler und Sportlerin über ihre Performance direkt informiert werden sollen. Die Wahl der Art des Feedbacks hängt nicht zuletzt von der Bewegung bzw. Sportart selbst ab: Explorative Studien, in denen drei verschiedene Arten von Feedback miteinander verglichen wurden, ergaben, dass visuelles Feedback bei Schwimmern und Schwimmerinnen besser funktionieren, wohingegen Schall und Vibration besser bei Bergsteigern und Bergsteigerinnen funktionieren (Mencarini et al., 2019).

**Für den Spitzensport bedeutet das:**

Extrinsisches Feedback kann im Wesentlichen visuell, akustisch und/oder haptisch erfolgen und ist je nach Sportart individuell einzusetzen.

Die Arbeit von Mencarini et al. (2019) verdeutlicht, dass die Forschung im Bereich der Mensch-Maschine-Interaktion in vielerlei Hinsicht noch in den Kinderschuhen steckt. So werden insbesondere die technischen Aspekte des Designs beleuchtet, wohingegen die Auswirkungen der Technologie bezogen auf die Benutzererfahrung übersehen werden. Mencarini et al. (2019) identifizieren sechs Richtungen für die Erforschung von Sportler-Wearables:

1. Während aktuell insbesondere die Erforschung von Armbanduhren mit Echtzeitfeedback dominiert, so wird noch kaum in die Erforschung von „Smart Clothing“ investiert.
2. Die derzeitige Forschung richtet sich primär an Athleten und Athletinnen aus dem Amateur- und Breitensport, sodass zukünftige Forschungsbemühungen den Spitzensport miteinbeziehen sollten.
3. Die komplexe Konstellation von kognitiven, emotionalen und sozialen Aspekten sollten unter Einbeziehung der Erfahrungen der Sportpraxis ebenfalls abgedeckt werden.
4. Eine weitere faszinierende Forschungsrichtung könnte sich aus technologischen Artefakten herleiten, welche das Sporterlebnis durch die Ermöglichung radikal neuer Praktiken verändern können.
5. Die Anbindung tragbarer Geräte an das breitere IoT-Ökosystem eröffnet neue Dienstleistungen und Möglichkeiten der Interaktion.
6. Rigorosere methodische Ansätze sind sowohl für die Analyse der Bedürfnisse der Benutzer und Benutzerinnen sowie für die Bewertung der technologischen Artefakte notwendig.

**Für den Spitzensport bedeutet das:**

Bezogen auf den Teilschritt I steht die Entwicklung von Wearables für den spezifischen Einsatz im Spitzensport noch am Anfang. Da die gegenwärtige Entwicklung von Wearables meistens produkt- und technologiegetrieben ist, wird insbesondere das Klientel der Hobby- und Breitensportler bedient, jedoch nicht die Aktiven im Spitzensport. An dieser Stelle sollte mehr Mut gezeigt werden, den Entwicklungsprozess umzudrehen und primär auf die Bedürfnisse des Spitzensports eingegangen werden. Es werden daher Forschungsrichtungen wie die Anbindung an breitere IoT-Ökosysteme, die Erforschung der Auswirkungen durch den Einsatz von Wearables auf die Trainingspraxis, Smart Clothing sowie die Entwicklung von Geräten, die sich mittels einer besseren Individualisierung auch an die Bedürfnisse von Spitzensportler und Spitzensportlerinnen richten, empfohlen.

### 3.4.2 Simulation / VR / AR

Eine wichtige Entwicklung ist die Integration von Trainings- oder Bewegungsabläufen in Virtual Reality (VR) oder Augmented Reality (AR). Hier gibt es inzwischen viele Ansätze aus unterschiedlichen Domänen (Adhani et al., 2012). Die Akzeptanz von VR- und AR-Systemen wurde bereits von (Gradl et al., 2016) mit 227 Probanden untersucht. Die Ergebnisse zeigen, dass rund zwei Drittel der Teilnehmer und Teilnehmerinnen einer Nutzung von VR und AR positiv gegenüberstehen. Colley et al. (2015) beschreiben ein Konzept zur Verwendung eines Head Mounted Display (HMD) beim Skifahren und Snowboarden. Der Träger des HMDs fährt auf einer Strecke, welche über das HMD in einer virtuellen Realität abgebildet wird. Darüber hinaus ist der HMD-Träger mit weiteren sensorischen Inputs verbunden, was ihm das volle Erlebnis des Skilaufens aus der realen Welt verleiht. Der Prototyp dieses Gerätes wurde in der Realität evaluiert, wobei aus dem Feedback der Testpersonen abzuleiten ist, dass der erreichte Grad der Immersion hoch ist. Weitere Anwendungen sind beim Training am Arbeitsplatz (Besbes et al., 2012), im Schulunterricht (Dunleavy et al., 2014), im Sport durch Augmentati-

on für den Ausgleich von unterschiedlichen Fähigkeiten von Spielern in Ballsportarten (Sano et al., 2016), beim Bewegungstraining an AR Spiegeln (Anderson et al., 2013) und bei haptischen Interfaces unter Hilfestellung von Exoskeletten (Tsetserukou et al., 2010).

**Für den Spitzensport bedeutet das:**

Die Entwicklung von Virtual und Augmented Reality ist in vielen Domänen weit fortgeschritten und kann auch für Realzeitanwendungen wie Bewegungstraining eingesetzt werden. Virtual und Augmented Reality erlauben eine Rückkopplung zwischen KI und Sportler und Sportlerin unter beherrschbaren und veränderbaren Umgebungsbedingungen. Die Akzeptanz von Feedbacksystemen im Spitzensport kann durch Augmented Reality erhöht werden.

Das Generieren von Simulationsumgebungen kann auch durch generative Modelle teilweise übernommen werden (Hsieh et al., 2019). In der genannten Arbeit zum Basketball wurde die KI u. a. dazu eingesetzt, Basketballsimulationen anhand von menschlichen Skizzen zu generieren. Dies kann zu einer schnellen Interaktion zwischen Trainer/Trainerin und Spieler/Spielerin beitragen.

**Für den Spitzensport bedeutet das:**

Generative Modelle können aus Skizzen Simulationsumgebungen erstellen. Die Skizze ist als handwerkliches Werkzeug auch im Spitzensport von Bedeutung. Wird aus der Skizze automatisiert eine Simulation erzeugt, so kann diese als ein weiteres didaktisches Hilfsmittel im Training eingesetzt werden.

Die Lücke zwischen Simulation und Realität, welche auch noch weiterhin besteht, kann durch Simulationsadaption auf Basis realer Daten teilweise geschlossen werden. Hierzu werden häufig iterative und interaktive Verfahren eingesetzt (Chebotar et al., 2019; Xie et al., 2020).

**Für den Spitzensport bedeutet das:**

Es besteht weiterhin eine Lücke zwischen Simulation und Realität, aber es gibt verschiedene Ansätze, um diese Lücke zu verkleinern.

Es kann bei der Verwendung von simulierten Umgebungen eine auf realen Daten basierte Interaktion und Adaption stattfinden.

### 3.4.3 Dimensionsreduktion und Visualisierung

Um hochdimensionale Daten darzustellen, zu clustern oder anderweitig zu analysieren, werden häufig Methoden der Dimensionsreduktion angewandt. Diese Methoden erlauben es, hochdimensionale Daten in einen Raum mit weniger Dimensionen zu transformieren, sodass beispielsweise Cluster besser unterschieden werden können (Tomašev et al., 2016). Eine der hierfür am häufigsten eingesetzten Methoden ist t-distributed Stochastic Neighbourhood Embedding (t-SNE) (Maaten et al., 2008). T-SNE wird häufig zur Visualisierung verwendet und hat sich als geeignet erwiesen, die lokale Struktur der Daten beizubehalten und Cluster in verschiedenen Maßstäben aufzudecken. Das Verfahren zielt darauf ab, eine niedrigdimensionale Verteilung der Punkte zu finden, die der ursprünglichen hochdimensionalen Verteilung ähnelt.

**Für den Spitzensport bedeutet das:**

Dimensionsreduktionsmethoden, welche auch lokale und/oder globale Strukturen von hochdimensionalen Daten erhalten, erlauben es dem Menschen die Daten zu sichten und Zusammenhänge, wie z. B. Cluster, zu erkennen. Auf diese Weise werden Daten für den Nutzer oder die Nutzerin zugänglicher.

Um die Transparenz und das Verständnis (und somit die Akzeptanz) von KI-Systemen zu vergrößern, muss die Visualisierung von Ergebnissen so informativ und zugleich so effektiv wie möglich gestaltet werden. Wenn komplexe Daten oder Optimierungsergebnisse vermittelt werden sollen, können unter anderem Dimensionsreduktionsmethoden unterstützend eingesetzt werden.



# Möglichkeiten der KI im Spitzensport

4





Zunächst werden die Eigenschaften und Gegebenheiten des Spitzensports, bezugnehmend auf deren Einfluss auf die Verwendung von KI, unter den Aspekten „*methodologischer Mismatch*“, „*struktureller Mismatch*“ und „*mangelnde Awareness*“ im Spitzensport aufgearbeitet und vertieft.

Der Spitzensport hat eine Daten- und Methodenlage, die mit den neuen Entwicklungen in der KI teilweise im Widerspruch stehen. So führt der natürliche Konkurrenzdruck zwischen Sportlern und Vereinen, aber auch zwischen Unternehmen der Industrie von z. B. Sport- und Trainingsgeräten, dazu, dass sowohl mit den erhobenen Daten als auch mit den verwendeten Methoden und Sensoren nicht „offen“ umgegangen wird. Neuere Entwicklungen in der KI beruhen aber meistens genau darauf, dass Daten und Methoden offen zur Verfügung gestellt werden. Die KI-Community ist es gewohnt, dass sie vieles „einfach“ ausprobieren kann, weil sowohl große und gut dokumentierte Datenmengen als auch Methoden zur Verfügung stehen. Im Gegensatz dazu ist die Sensorik von z. B. Wearables meist *Closed Source*, also steht nicht zur Analyse und Weiterverwertung zur Verfügung. Sogenannte APIs, also Schnittstellen zu den Geräten, werden von den Herstellern nicht unbedingt so angeboten, wie man das zum Beispiel in der autonomen Robotik oder der maschinellen Wahrnehmung (z. B. Computer Vision) gewohnt ist. Das führt dazu, dass Sportdaten nicht von einem größeren Personenkreis (z. B. Wissenschaftlern und Wissenschaftlerinnen, Ingenieuren und Ingenieurinnen, Entwicklern und Entwicklerinnen usw.) für die Entwicklung und/oder Forschung verwendet werden können.

## 4.1 Methodologischer Mismatch

Im Spitzensport besteht häufig das Problem, dass Daten nur von wenigen Personen häufig nicht repräsentativer Gruppen zur Verfügung stehen. Dies behindert besonders die Anwendung maschineller Lernverfahren. Trotz großer Datenmengen handelt es sich also eher um Small Data, was in der Natur der Sache liegt. Dies hat zur Folge, dass trotz der umfangreichen Daten viele Methoden der

KI, insbesondere die des maschinellen Lernens, kaum angewendet werden können, weil insbesondere statistische Methoden meistens nur gut generalisieren und sich für zukünftige Vorhersagen nutzen lassen, wenn die Daten vieler unterschiedlicher Personen (Big Data) verwendet werden. Daher sind Big Data Ansätze, worunter insbesondere die Methoden des Deep Learning einzuordnen sind, in der Regel im Spitzensportbereich kaum einsetzbar.

„Small Data“ im Gegensatz zu „Big Data“ lässt sich so definieren, dass grundsätzlich die Datenmenge geringer und der Vorhersagefehler höher ist, was ebenfalls mit der Größe des Trainingsdatensatzes zusammenhängt (vgl. Abb. 4).

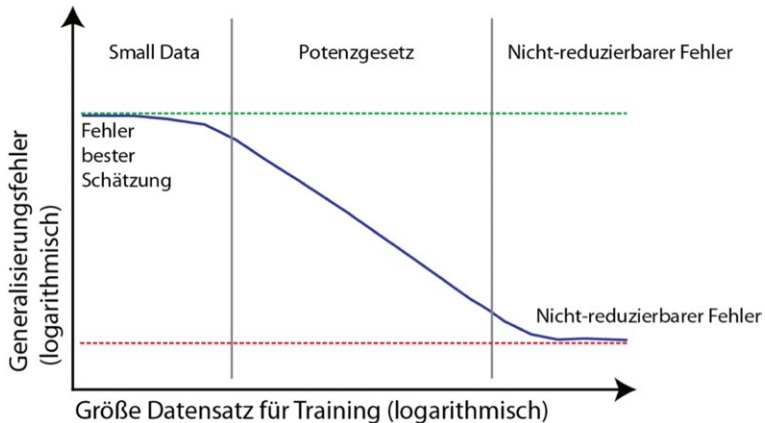


Abb. 4: Datenmenge und Vorhersagefehler für Small und Big Data im Vergleich (vgl. Hestness, 2017).

### Für den Spitzensport bedeutet das:

Einerseits könnten Datensätze unter Sportlern und Sportlerinnen geteilt werden, um bestimmte Problemstellungen mit Methoden der KI zu lösen. Andererseits muss im Hinblick auf die Genauigkeit und Generalisierungsfähigkeit von KI-Systemen mit kleinen Datensätzen auch methodisch agiert werden.

Neue Entwicklungen in der KI sind aber auch aus anderen Gründen nicht immer für den Einsatz im Spitzensport geeignet. So gibt es zum Beispiel einen Mismatch bezogen auf die Realzeit- und Portabilitätsanforderungen des Spitzensports. So müssen beispielsweise Wearables mit einer stark reduzierten Leistungsfähigkeit auskommen.

**Für den Spitzensport bedeutet das:**

Realzeit- und Portabilitätsanforderungen führen möglicherweise zu einer Verwendung weniger leistungsstarker KI-Methoden. Dies muss manchmal in Kauf genommen werden, aber das Trade-Off zwischen Leistung und Portabilität kann weiter erforscht werden.

Außerdem sind die Daten, je nach Sportart, nicht immer von hoher Qualität. Insbesondere bei biologischen Daten muss ein gewisses Datenrauschen häufig in Kauf genommen werden, weshalb die Robustheit der verwendeten KI-Methoden für den erfolgreichen Einsatz im Spitzensport von großer Bedeutung ist.

**Für den Spitzensport bedeutet das:**

Ein Schwerpunkt bei der Anwendung von KI sollte bei der Entwicklung robuster Methoden liegen.

Die Ungenauigkeit und Tendenz zu ständiger Innovation bei datengetriebenen und optimierenden KI-Systemen könnten außerdem im realen Einsatz im Spitzensport durch den Einsatz unerprobter Methoden z. B. auch zu Verletzungen führen. Dies sollte bei der Entwicklung solcher Systeme immer in Betracht gezogen werden, aber nicht dazu führen, dass Innovation verhindert wird.

**Für den Spitzensport bedeutet das:**

Innovation und Risiken müssen gegeneinander abgewogen werden.

## 4.2 Struktureller Mismatch

Um die Anwendungsmöglichkeiten einer datengetriebenen KI im Spitzensport besser beurteilen zu können, ist es zunächst hilfreich, sich anzuschauen, worin sich die Gegebenheiten von anderen Anwendungsdomänen der KI unterscheiden. Der fixe Rahmen, der durch die Strukturen im Spitzensport gegeben ist (Verbände, Vereine, Trainingsgruppen und -teams) und der intrinsische Hang zu Wettbewerbsvorteilen und kommerzieller Verwertbarkeit entspricht nicht den üblicherweise in der KI vorzufindenden Strukturen. Dort herrschen agile Entwicklungsstrukturen, Open Source und freizügiges Publizieren von Ergebnissen, Daten und Methoden.

Die vorliegende Expertise kann und soll einen Beitrag dazu leisten, zukünftig Entwicklungen aus der KI besser in den Spitzensport zu tragen. Hierfür muss gegebenenfalls ein Umdenken im Sport erfolgen, oder zumindest eine Suche nach Kompromissen zwischen Wettbewerbsvorteil auf internationaler und nationaler Ebene und möglichen Vorteilen des Einsatzes von KI. Gleichzeitig gilt es bei KI-Experten und KI-Expertinnen ein Interesse an sportspezifischen Daten, Methoden und Anforderungen zu wecken bzw. falls vorhanden, dieses zu erhöhen, damit eine Integration der beiden Felder leichter erfolgen kann und die Sportinformatik methodisch bereichert wird.

### **Für den Spitzensport bedeutet das:**

Das Angebot von freien und offenen Datensammlungen und Methoden würde innerhalb der KI-Gemeinschaft auf positive Resonanz stoßen; die spezifischen Eigenschaften von Sportdaten können so einfacher in die Entwicklung robuster Methoden der KI fließen.

Davon ausgehend, dass es im Spitzensport Bereiche gibt, in denen KI sinnvoll zur Problemlösung eingesetzt werden könnte, die Daten jedoch aufgrund nachvollziehbarer Gründe nicht zur freien Verfügung gestellt werden (oder werden können), muss die Datenlage innerhalb von „Closed Source“ Projekten beurteilt werden.

## 4.3 Mangelnde Awareness

Eine wichtige Voraussetzung für die erfolgreiche Umsetzung neuer Methoden ist die Akzeptanz solcher Methoden bei allen beteiligten Personen (u. a. Trainer und Trainerinnen und Sportler und Sportlerin). Weiterhin gibt es auf Ebene der Wissenschaft ein Sprachproblem zwischen den beiden Bereichen „Spitzensport“ und „KI“. Diese Arbeit erhofft sich dazu beizutragen, dass Termini und Konzepte aus der KI anhand von Beispielen (sowohl in der Analyse als auch in der Definition von Use Cases) verständlich erklärt werden.

### **Für den Spitzensport bedeutet das:**

Ausschreibungen und Veröffentlichungen der Anwendung der KI im Spitzensport sollten allen Beteiligten / involvierten Personengruppen sprachlich gerecht werden.

Eine zweite mögliche Schwelle ist das Verständnis der Methoden und der Algorithmik in beiden Forschungsbereichen. Die bislang in der Sportwissenschaft eingesetzten Methoden sind KI-Forschenden in der Regel nicht bekannt und umgekehrt. Hier ist es wichtig, z. B. über die Veröffentlichung von Daten und Methoden in einer gemeinsamen Sprache, ein Verständnis für die Methoden der jeweilig anderen Disziplin zu entwickeln. Dies könnte beispielsweise über spezielle Studienprogramme, Workshops oder auch Summer Schools in den Studiengängen der Informatik und der angewandten Mathematik erfolgen, um so eine Basis für die Entwicklung einer Community aus Sport- und KI-affinen Forscher und Forscherinnen und Entwickler und Entwicklerinnen (nicht nur Studierenden) zu legen. Auf diese Weise kann auch die Problematik der fehlenden wechselseitigen Awareness adressiert werden.

### **Für den Spitzensport bedeutet das:**

Die Entwicklung einer Sport-KI-Community und die spezifische Förderung Community-getriebener Veranstaltungen kann das gegenseitige methodische Verständnis erhöhen.

Die von Russel und Norvig (2020) definierte Handlungsschleife einer künstlichen Intelligenz wird im Spitzensport häufig nicht geschlossen. Meistens werden nur die ersten beiden Teilschritte **S** „Sensorik, Messung und Wahrnehmung“ und **M** „Modellierung, Lernen und Vorhersage“ abgebildet. Demgegenüber ist es im Freizeitsport durch die Verwendung von z. B. Smart Watches bereits in einzelnen Fällen gelungen, die Interaktionsschleife zu schließen. Um auch im Spitzensport KI gewinnbringend anzuwenden, ist eine gewisse Interaktion der Trainer und Trainerinnen und Sportler und Sportlerinnen mit der KI von zentraler Bedeutung. Denn nur, wenn im Rahmen der KI konkrete Vorschläge gemacht werden, die innerhalb eines – gemessen an den bisherigen Erfahrungen und Erkenntnissen – üblichen Rahmens liegen, kann die Akzeptanz für die Anwendung aller vier Teilschritte der KI erhöht werden.

**Für den Spitzensport bedeutet das:**

Die Art der Interaktion der KI mit Trainer und Trainerinnen und Sportler und Sportlerinnen kann einen wesentlichen Unterschied machen. Wenn die Algorithmik Vorschläge innerhalb des „üblichen Rahmens“ macht, kann die Akzeptanz zur besseren Integration von KI erhöht werden.

# Use Cases

5







- S** Die Messung über Sensorik dient der Erfassung des „Systemzustandes“, während die KI mit dem „System“ interagiert. Im vorliegenden Fall ist dies im Wesentlichen der interne und externe Training-Load der Athleten während des Trainings. Näheres zu den in der Studie verwendeten Messwerten findet sich im Kapitel S: Sensorik und Datenerfassung.
- M** Im Modellierungsschritt muss in einem Computermodell nachgebildet werden, wie Trainierende auf eine Trainingsbelastung reagieren. Dies zeigt sich einerseits durch eine Reaktion innerhalb der Trainingseinheit (z. B. Anstieg der Herzfrequenz als Beanspruchungsmaß/internal load) und andererseits durch Anpassungen (Response) zwischen Trainingseinheiten bzw. im Laufe mehrerer Tage bis Wochen im Sinne der sportartspezifischen Leistungsfähigkeit. Letzteres äußert sich zum Teil indirekt durch eine veränderte kurzfristige Reaktion (z. B. Herzfrequenzreaktion) auf Belastungen während des Trainings. Aus diesem Grund wurde der Modellierungsschritt der KI zweigeteilt, wobei die Modellierung der Reaktionen innerhalb einer Trainingseinheit als Grundlage einer virtuellen Leistungsdiagnostik (simulierte Leistungsfähigkeit) dient, auf deren Basis wiederum die Modellierung der langfristigen, tagesübergreifenden Anpassungen erfolgt. Nähere Informationen hierzu finden sich im Abschnitt M/1: Herzfrequenz-Modellierung und M/2: Trainings-Wirkungs-Modellierung.
- P** Im Planungsschritt werden für ein vorgegebenes Trainingsziel passende Trainingsempfehlungen auf Basis der Modelle aus Schritt M/1 und M/2 generiert. Im Allgemeinen ist dabei nicht davon auszugehen, dass einzelne generierte Trainingspläne alle Faktoren berücksichtigen können, die bei der Auswahl einer geeigneten Trainingseinheit an einem bestimmten Tag relevant sind. Aus diesem Grund wird an dieser Stelle ein Unterstützungssystem entwickelt, das Trainer und Athlet jeweils eine Auswahl an Trainingsplänen und -einheiten präsentiert und die finale Auswahl schließlich beim Menschen liegt. Durch die verschiedenen möglichen Wege zur Erreichung des Trainingsziels erhöht sich die Wahrscheinlichkeit, dass sich eine in der Praxis durchführbare, realistische Trainingsempfehlung auswählen

lässt. Dafür muss einerseits die Belastungs-Sequenz zum aktuellen (Trainings)Zustand passen und sich andererseits die konkrete Ausgestaltung einzelner Trainingseinheiten nahtlos in die sich täglich verändernden Rahmenbedingungen implementieren lassen. Nähere Informationen finden sich im Abschnitt P/1: Belastungs-Sequenz-Generierung und P/2: Trainings-Generierung.

- I In die eigentliche Intervention ist das KI-System nur marginal involviert. Die jeweils ausgewählten Trainingspläne aus Schritt P dienen als Grundlage der durchzuführenden Trainingseinheiten. Diese können z. B. durch Fahrradcomputer visualisiert werden und den Athleten so Hilfestellungen bei der Durchführung gegeben werden. Gleichzeitig werden die tatsächliche Ausführung sowie die Reaktion auf die Belastung gemessen (Schritt S), sodass die Informationen in Schritt M für eine Aktualisierung des Modells verwendet werden können.

### **5.1.1 Methodische Festlegungen des anwendungsspezifischen SMPI-Zyklus**

Bei der Umsetzung des Use Case wurden eine Reihe von Festlegungen getroffen, die mehrere oder alle Schritte des SMPI-Zyklus betreffen und unabhängig von den in den einzelnen Schritten verwendeten Verfahren sind. Im Folgenden werden die wichtigsten Entscheidungen dargestellt und begründet.

#### **5.1.1.1 Zykluslänge**

Die durch ein sportliches Training beabsichtigten zeitlich verzögerten Anpassungsreaktionen sind im Allgemeinen erst nach einer gewissen Rekompensationsphase zu erwarten. Für die konkrete Realisierung dieses Use Case wurde die Länge eines Zyklus der KI-Schleife daher auf sieben Tage festgelegt, sodass die Rückkopplung an die Sensorik nicht zu früh stattfindet. Außerdem hat diese Festlegung den Vorteil, dass die Trainingsplanung (siehe Abschnitt P) in aus Sicht der Praxis sinnvollen und gängigen Zeitintervallen im Sinne eines wöchentlichen Mesozyklus stattfinden kann. Grundsätzlich ist die Länge eines Zyklus allerdings frei wählbar und

könnte theoretisch auch täglich oder immer beim Messen und Verarbeiten aktueller Daten erfolgen, solange die durch die Manipulation des KI-Systems zu erwartenden Effekte auch innerhalb eines Zyklus beobachtbar bzw. messbar sind.

### **5.1.1.2 Benutzerinteraktion**

Eine vollautomatisierte KI-Schleife ergibt im Trainingsprozess insbesondere aufgrund der essentiellen Interaktion und dem Erfahrungsaustausch zwischen dem Athleten bzw. der Athletin und dem betreuenden Personal wenig Sinn. Sowohl individuelle Trainingsziele als auch die konkrete Planung des täglichen Trainings unterliegen natürlichen Einflüssen und lassen sich in ihrer Ganzheitlichkeit mit der verfügbaren Sensorik nicht immer vollständig abbilden. Das KI-System wird deshalb an verschiedenen Stellen durch Interaktion mit Auswahl konkreter Vorschläge durch Menschen gesteuert. Darunter fallen beispielsweise die Auswahl einer von mehreren vorgeschlagenen Trainings-Sequenzen und individuellen Belastungsprofilen jeder dazugehörigen Trainingseinheit zu Beginn eines neuen KI-Zyklus.

## **5.1.2 S: Sensorik, Messung und Wahrnehmung (Datenerfassung)**

### **5.1.2.1 S/0: Probandenkollektiv und Studiendesign**

Die im Rahmen des Use Case Trainingssteuerung rekrutierten männlichen Probanden ( $n = 3$ , alle U23 der Jahrgänge 1998 bis 2001) bilden verschiedene Ebenen der Leistungsfähigkeit ab (Nationalkader, Landeskader und Amateur). Die Datenerfassung startete im August 2020 und wurde bis inklusive Dezember 2020 unter enger Begleitung und Betreuung des Trainers vor Ort durchgeführt. Das Training wurde zuerst mit Blick auf die im September und Oktober absolvierten Wettkämpfe individuell gesteuert und umfasste im zweiten Teil des Studienzeitraums, unter anderem bedingt durch die Einschränkungen der Corona-Pandemie und die Transition in ein saisonvorbereitendes Grundlagentraining, erhöhte Anteile an

radfahrerspezifischem Krafttraining. Studienbegleitend wurden alle vier bis fünf Wochen insgesamt vier Leistungsdiagnostiken im Labor durchgeführt.

Im realisierten KI-Ansatz ist die engmaschige und umfassende Erfassung des „Systems Athletin/Athlet“ im Sinne des Athletenmonitorings eine notwendige Voraussetzung, um regelmäßige Feedback-Loops zu ermöglichen. Deshalb wurde der Zustand der Trainierenden über den gesamten Studienzeitraum durch verschiedene Parameter hinsichtlich der Belastungen und resultierenden Beanspruchungen im Trainingsprozess sowie der Leistungsfähigkeit bzw. Athletenreaktion (Response) dokumentiert. In den nächsten beiden Abschnitten werden die dabei zum Einsatz gekommenen Methoden und Messverfahren beschrieben und die exemplarische Auswahl für die realisierte KI-Schleife dargelegt.




Abb. 6: Exemplarische Darstellung der Trainingsdauer unter- und oberhalb der VT2 (blaue/rote Balken, vgl. Abschnitt S/1) und der virtuellen Leistungsfähigkeit (rote Kreuze, vgl. S/2 und M/1) von Proband 1 im Verlauf des Studienzeitraums von August bis Dezember 2020.

### 5.1.2.2 S/1: Belastung und Beanspruchung

Radfahrerspezifisches Training und die daraus resultierenden adaptiven Reize können durch eine Vielzahl von Kennwerten quantifiziert werden. Neben aggregierten Informationen wie beispielsweise dem Trainingload mit Hilfe des Session-RPE oder der Trainingsdauer einer einzelnen Trainingseinheit bzw. eines gesamten Tages können ebenso die zeitlichen Verläufe verschiedener Kennwerte der Belastung und Beanspruchung innerhalb jeder einzelnen Trainingseinheit, wie beispielsweise die Herzfrequenz, selbst erfasst werden. Eine Übersicht der erhobenen und schließlich für die kon-

krete Umsetzung der KI-Schleife genutzten Parameter bezüglich des Trainings kann Tabelle 1 entnommen werden.

Tab. 1: Übersicht der für den KI-Schritt S (Wahrnehmung und Sensorik) erhobenen Parameter bezüglich des Trainings. Die im realisierten Use Case im Radfahren exemplarisch genutzten Informationen sind fett markiert.

	Aggregierte Informationen (pro Einheit / tageweise)	Zeitliche Verläufe (Rohdaten)
Belastung (External Load)	Gesamtzeit der Fahrt <b>Fahrzeit pro Trainingsbereich nach Watt</b> Energieverbrauch in kJ <b>Trainingsinhalt (Anzahl Intervalle, Intensitäten usw.)</b>	<b>Belastung [Watt]</b> Höhe Geschwindigkeit Trittfrequenz Temperatur
Beanspruchung (Internal Load)	Trainingload (Session-RPE Methode) Fahrzeit pro Trainingsbereich nach Herzfrequenz <b>Training Impulse (TRIMP)</b> Training Stress Score (TSS)	<b>Herzfrequenz</b>

### 5.1.2.3 S/2: Athletenreaktion (Response) und radsportspezifische Leistungsfähigkeit

Die Athletenreaktion im Sinne der individuellen Response im Trainingsprozess kann grundsätzlich auf verschiedenen Ebenen betrachtet werden. Neben psychometrischen Informationen wie beispielsweise dem akuten Belastungs- und Beanspruchungszustand lassen sich darunter auch physiologische Anpassungsreaktionen zusammenfassen, die sich zum Teil in der sportlichen Leistungsfähigkeit widerspiegeln. In dem vorliegenden Use Case wurde einmal im Monat eine radspezifische Leistungsdiagnostik im Labor durchgeführt und die Leistungsfähigkeit anhand der Kenngrößen  $V_{lmax}$ ,  $VO_{2max}$  und IANS ermittelt. Um die tägliche Trainingssteuerung durch ein KI-System zu unterstützen, sind jedoch engmaschig Informationen über den aktuellen Leistungsstand des Athleten erforderlich. Daher wurden die aufgezeichneten Trainingsdaten, d. h. die Watt-Herzfrequenz-Verläufe

genutzt, um eine radspezifische simulierte Leistungsfähigkeit für jeden Tag bestimmen zu können (vgl. Kapitel 5.1.3.1). Die Ergebnisse der Labordiagnostik sind im Rahmen der Trainingsplanung berücksichtigt worden, um beispielsweise die functional threshold power (FTP) zu bestimmen, auf der die Trainingsvorschläge basieren.

## 5.1.3 M: Modellierung, Lernen und Vorhersage

### 5.1.3.1 M/1: Herzfrequenz-Modellierung und simulierte Leistungsfähigkeit

Um die Leistungsfähigkeit der Fahrer in möglichst engmaschigen Zeitabständen überprüfen zu können, wurde für den vorliegenden Use Case der Ansatz verfolgt, die radspezifische Leistungsfähigkeit aus den bereits aufgezeichneten Leistungs- und Herzfrequenzdaten des Radfahrtrainings abzuleiten. Diesem Ansatz liegt die Annahme zugrunde, dass sich Rückschlüsse auf die radspezifische Leistungsfähigkeit ziehen lassen, wenn Belastung und Herzfrequenz (HF) in Relation zueinander betrachtet werden. Es wird angenommen, dass die Leistungsfähigkeit steigt, wenn bei gleicher Belastung ein geringeres HF-Niveau beobachtet wird (u. a. Arts & Kuipers, 1994; Meyer et al. 2020).

Diese Analogie soll in der praktischen Anwendung mit einem HF-Modell abgebildet werden, indem es zunächst die systematische Abhängigkeit zwischen Belastung und HF mithilfe maschineller Lernverfahren anhand von Beispielen aus den Datenaufzeichnungen der Trainingseinheiten „lernt“. Der für die „Lernphase“ zugrunde gelegte Datensatz umfasst dabei sämtliche Belastungs- und HF-Verläufe aus den Trainingseinheiten einer 14-tägigen Trainingsperiode. Auch wenn die Leistungsentwicklung eines Athleten oder einer Athletin innerhalb eines 14-tägigen Zeitfensters bereits sehr variabel sein kann, so wurde sich dennoch hierfür entschieden, da sich eine breitere Datenbasis vorteilhaft auf eine erfolgreiche Anwendung eines maschinellen Lernverfahrens auswirkt.

Nach Abschluss der Lernphase können mit dem Modell für beliebige Belastungsprofile die hierzu korrespondierenden HF-Verläufe simuliert werden. In diesem Kontext wird im Rahmen einer virtuellen Leistungsdiagnostik der zeitliche Verlauf einer

HF-Kurve für ein festgelegtes Belastungsprofil simuliert (vgl. Abb. 7). Ein solches Belastungsprofil wurde synthetisch in Anlehnung an ein in der Leistungsdiagnostik übliches Stufenprotokoll sowie darauffolgende Intervalle verschiedener Längen und Intensitäten realisiert. Um nun auf den Leistungsstand eines Athleten schließen zu können, wird der zur simulierten HF-Kurve korrespondierende TRIMP-Wert berechnet und als Leistungsindikator verwendet (simulierte Leistungsfähigkeit). Hierbei ist gemäß der bereits beschriebenen Annahme zu erwarten, dass niedrige TRIMP-Werte ein höheres und höhere ein niedrigeres Leistungsniveau abbilden.

Die oben beschriebene Vorgehensweise wurde für jeden weiteren Studientag wiederholt, wobei die Rohdaten des neuen Trainingstages mit in den Datensatz aufgenommen wurden. Analog dazu wurden jene Trainingsdaten, die bereits länger als 14 Tage in der Vergangenheit zurückliegen, aus dem Datensatz herausgenommen. Mit dieser Herangehensweise konnte für jeden weiteren Tag, an dem ein Training tatsächlich stattgefunden hat, die Leistung des Athleten neu abgeschätzt werden, sodass sich die Leistungsentwicklung des Athleten über den gesamten Saisonverlauf wesentlich engmaschiger abschätzen ließ als mit den Leistungsdiagnostiken aus dem Labor (vergleiche auch Abschnitt S/2 Athletenreaktion (Response) und Leistungsfähigkeit).

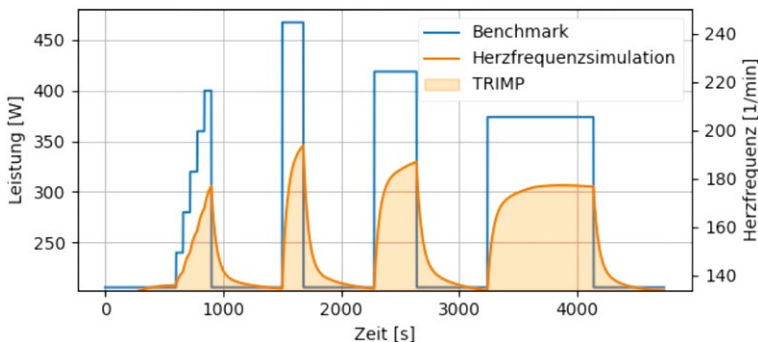


Abb. 7: Beispielhafte Darstellung eines synthetischen Belastungsprofils („Benchmark“, blaue Linie), welches für die Bestimmung der simulierten Leistungsfähigkeit verwendet wurde, sowie die hierzu korrespondierende HF-Kurve (orange Linie) mit dem hierzu errechneten TRIMP-Wert [gewichtete Fläche unterhalb der HF-Kurve].



In der konkreten Umsetzung des HF-Modells wurde ein lineares Regressionsmodell zugrunde gelegt, welches Belastungswerte einer beliebigen Zeitreihe zunächst glättet und anschließend auf die HF abbildet. Für die Wahl der Glättungsfunktion wurde sich für einen exponentiell gewichteten Gleit-Mittelwert (engl. exponentially weighted moving average, abk. EMA) entschieden, da dieser im Rahmen der HF-Modellierung bereits eine erste Angleichung der Belastungs- und HF-Zeitverläufe bewirkt. Dies ist bei einer passenden Wahl des Glättungsparameters insbesondere auf den kurzfristigen – d. h. ein für wenige Sekunden andauernder – Verzögerungseffekt in der Zeitreihe der Belastungswerte zurückzuführen, welcher in einer sehr ähnlichen Form auch im zeitlichen HF-Verlauf zu erkennen ist. Darüber hinaus wurde angenommen, dass auch längerfristig zurückliegende Vorbelastungen noch einen gewissen Einfluss auf die gegenwärtige HF-Prognose haben. Demzufolge wurden die Belastungswerte der originären Zeitreihe mit einem zweiten EMA geglättet, wobei der Glättungsparameter so gewählt wurde, dass ältere Belastungswerte aus der Zeitreihe wesentlich stärker bei der Mittelwertbildung gewichtet werden. Zur vollständigen Implementierung des Regressionsmodells werden schließlich die beiden Mittelwerte mit einem hierfür passenden Parametersatz auf die HF linear abgebildet, also:

$$EMA(p, \lambda_1) * a + EMA(p, \lambda_2) * b = HF \quad \text{mit} \quad EMA(p, \lambda) = \frac{\sum_{i=0}^t e^{-\frac{i}{\lambda}} p_{t-i}}{e^{-\frac{t}{\lambda}}}$$

Hierbei entspricht  $p$  einer beliebigen Zeitreihe von Belastungswerten,  $\lambda_1$  bzw.  $\lambda_2$  dem Glättungsparameter des jeweiligen EMAs und  $a$  bzw.  $b$  den Modellparametern.

Neben diesem Modell wurden noch weitere HF-Modelle hinsichtlich der Anwendbarkeit auf den vorliegenden Use Case untersucht. Hierzu zählt zum einen das HF-Modell von Ludwig et al. (2019a) sowie eine abgewandelte Form des probabilistischen Modells von Asteroth et al. (2020). Hierbei musste im Falle des HF-Modells von Ludwig et al. (2019a) jedoch festgestellt werden, dass sich ein für die HF-Prognose passender Parametersatz auf Basis der im freien Feld gemessenen Belastungs- und HF-Daten nicht immer bestimmen ließ. Im Falle des Ansatzes von Asteroth et al. (2020) wurden die beiden EMAs mittels einer Gauß-Prozess-Regression

(Rasmussen & Williams, 2008) auf eine HF abgebildet (vgl. auch Kapitel 3.1.2.5). Auch wenn mit diesem Ansatz die HF in einer vergleichbaren Vorhersagegüte prognostiziert werden konnte wie mit dem linearen Regressionsmodell, so erwies sich die praktische Anwendung des Ansatzes zum Zwecke einer reinen HF-Modellierung aufgrund einer zu hohen Anzahl von Messwerten als zu speicher- und berechnungsintensiv.

### 5.1.3.2 M/2: Trainings-Wirkungs-Modellierung

Um die Wirkung des Trainings auf die Leistungsfähigkeit im Sinne einer langfristigen, tagesübergreifenden Anpassung zwischen Trainingseinheiten abzubilden, wurden verschiedene Trainings-Wirkungs-Modelle (u. a. Fitness-Fatigue-Modell) evaluiert und hinsichtlich Ihrer Nutzbarkeit in diesem Szenario bewertet (Ludwig et al., 2019b; Rasche & Pfeiffer, 2019; Stephens Hemingway et al., 2020; Swinton et al. 2021). Aufgrund der Expertise der Antragsteller im Bereich der antagonistischen Modellierung, dem Vorliegen von Small-Data im Sinne der Expertise und der möglichen Einbeziehung von zwei Trainings-Variablen, wurde das Meta-Modell „Performance-Potential Double-Modell“ (Abkürzung: „PerPot DoMo“, Perl & Pfeiffer 2011; Perl, 2012) an das Anwendungsszenario angepasst und in die KI-Schleife implementiert.

Das PerPot DoMo verarbeitet zwei unabhängige Input-Variablen und bildet diese durch eine zeitlich verzögerte und jeweils positive und negative Wirkung auf eine abhängige Output-Variable ab (siehe Abb. 8). Das Modell basiert auf Flussgleichungen und daraus resultierenden Flussraten, die zwischen Potenzialen verarbeitet werden. Grundsätzlich kann die konkrete Zeitspanne eines Schritts  $t \rightarrow t+1$  frei gewählt werden und wird in der vorliegenden Anwendung (wie auch üblicherweise im Kontext der Trainingswirkungsanalyse) tageweise interpretiert. Zusätzlich zu der internen Verarbeitung der jeweiligen Inputs (PerPot 1 und PerPot 2) können Interaktionsprozesse im Training durch Ankopplungsfaktoren (in Abb. 8 durch schwarze Verbindungslinien dargestellt) zwischen den beiden Modellseiten abgebildet werden, die die zeitlichen Verzögerungen der jeweils anderen Seite dynamisch verändern.

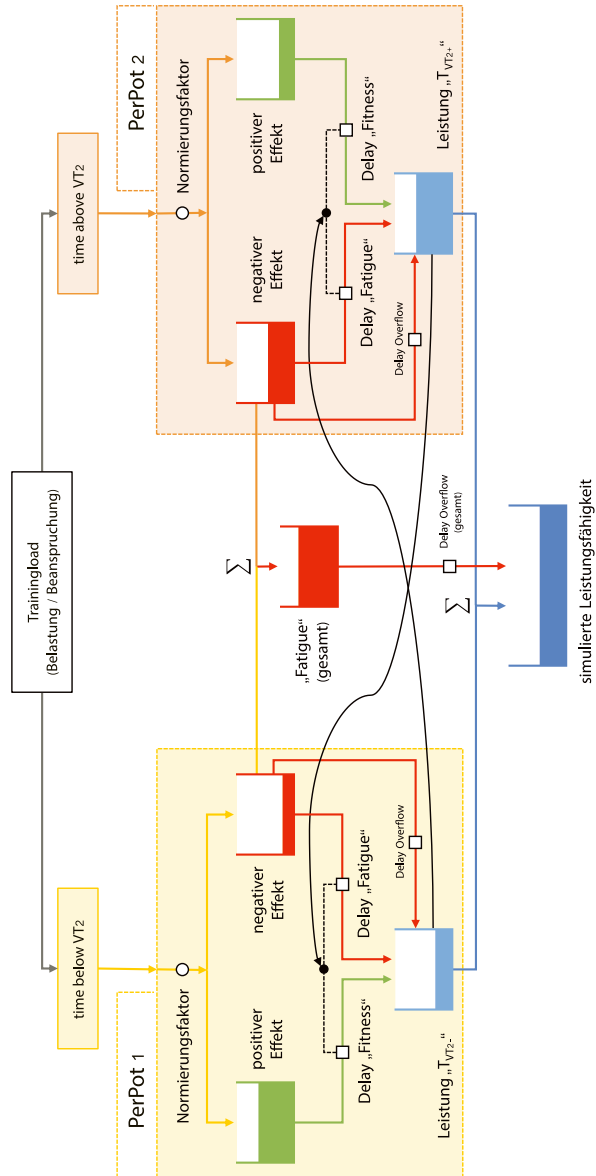


Abb. 8: Schematische Darstellung des in Schritt M/2 genutzten antagonistischen Performance-Potential Double-Modells (kurz: PerPot DoMo) inklusive Ankopplungsfaktoren (schwarze Pfeile). (eigene Darstellung in Anlehnung an Perl & Pfeiffer, 2011)

Im vorliegenden Use Case wurde als Modell-Input die täglich kumulierte Trainingsdauer oberhalb ( $T_{VT2+}$ ) und unterhalb ( $T_{VT2-}$ ) der zweiten ventilatorischen Schwelle (VT2, in Bezug auf die sekundliche Belastung in Watt) genutzt, um die unterschiedlichen Intensitätsbereiche im Training und die daraus resultierenden adaptiven Reize abzubilden. Die zweite ventilatorische Schwelle wurde im Rahmen der Leistungsdiagnostiken im Laufe der Studie mehrfach unter Laborbedingungen bestimmt, sodass die Dauer der Trainingseinheiten entsprechend in Abhängigkeit des aktuellen Werts kategorisiert werden konnten. Die Kalibrierung und Optimierungen der modell-internen Parameter erfolgt in 7-Tage-Schritten auf Basis des jeweils im Schritt P ausgewählten Trainings und der resultierenden simulierten Leistungsfähigkeit (vgl. Abschnitt M/1) für jeden Zyklus neu.

### 5.1.4 P: Planung, Strategie und Optimierung

Im Planungsschritt des KI-Zyklus werden zum einen Belastungs-Sequenzen (i. d. R. eine Trainingseinheit pro Tag) zur Erreichung eines Trainingsziels (z. B. 1% Leistungssteigerung) und zum anderen dazu passende tägliche Trainingsprofile generiert und jeweils durch Nutzerinteraktion ausgewählt. Die Anzahl der Vorschläge für beide Bereiche ist grundsätzlich frei wählbar, wurde aber für die Studie sowohl für die Sequenzen als auch die Trainingsprofile auf fünf unterschiedliche Varianten festgelegt. Die ausgewählten Trainingseinheiten werden schließlich im folgenden Interventionsschritt (I) „trainiert“ bzw. dienen wiederum als Informationen im Sinne des Sensorik-Schritts (S).

#### 5.1.4.1 P/1: Belastungs-Sequenz-Generierung

Das Trainings-Wirkungs-Modell PerPot DoMo aus dem vorangegangenen Schritt (M/2) dient als Grundlage zur Generierung von täglichen Trainingsvorschlägen für den aktuellen Zyklus. Auf Basis eines Trainingsziels (Z) für das Ende des 7-tägigen Planungszeitraums, das aus den empirischen Daten abgeleitet wird (vergleiche dazu auch Abschnitt Prototypische Umsetzung des SMPI-Zyklus),

wird eine Sequenz von Belastungen im Sinne des Modell-Inputs aus  $M/2$  ( $T_{VT2+}$ ,  $T_{VT2-}$ ) generiert. Dabei wird versucht, den Abstand zwischen der vom Modell aus  $M/2$  vorhergesagten Leistungsentwicklung ( $M$ ) und dem Ziel ( $Z$ ) zu minimieren, also:

$$|M - Z| \rightarrow \min$$

Als Eingabe für das Modell aus  $M/2$  dient eine Belastungs-Sequenz. Im Falle des Fitness-Fatigue-Modells ist dies z. B. eine Folge von TSS Werten, im Falle des PerPot-Double-Modells eine Folge von Paaren ( $T_{VT2+}$ ,  $T_{VT2-}$ ). Geht man von einem Training pro Tag aus, so geht es also darum, einen Vektor von sieben TSS-Werten, bzw. sieben ( $T_{VT2+}$ ,  $T_{VT2-}$ ) Paaren, zu optimieren. Als besonders effizientes Verfahren hat sich für diese Art von Problemen das CMA-ES Verfahren von Nikolaus Hansen (Hansen et al. 2001) bewährt, dass heute als *goldstandard* unter den evolutionären Strategien gilt. Neben der Optimierung des Trainingsziels erlauben evolutionäre Verfahren auf einfache Art die Berücksichtigung zusätzlicher Randbedingungen über sogenannte soft-constraints, sodass beispielsweise die Möglichkeit besteht Ruhetage zu erzwingen oder besonders intensive Trainingseinheiten auf bestimmte Tage zu legen.

Ausgabe dieses Schritts (P/1) ist eine Auswahl von fünf verschiedenen optimierten Belastungs-Sequenzen, die alle sowohl das Trainingsziel in der Simulation ( $M/2$ ) erreichen als auch die vorgegebenen Randbedingungen berücksichtigen (vgl. hierzu auch das Kapitel Prototypische Umsetzung des SMPi-Zyklus, Abschnitt Demonstrator).

#### 5.1.4.2 P/2: Trainings-Generierung

Die in P/1 per Nutzerinteraktion ausgewählte Belastungs-Sequenz definiert für jeden Trainingstag einen Belastungswert in Form des Inputs aus  $M/2$ , also die Trainingsdauer ober- und unterhalb der  $VT2$ . Dieser muss in eine trainierbare Form „übersetzt“ werden. Hierbei gibt es eine Vielzahl an Freiheitsgraden. In der Praxis haben sich verschiedene Muster etabliert, nach denen Trainingseinheiten im Radfahren ablaufen (z. B. Intervalle unterschiedlicher Länge / Wiederholungszahl / Pausenlänge etc.). Mit Hilfe eines Generators lassen sich solche Trainingseinheiten generieren, wenn die wesent-

lichen „Eckdaten“ eines Trainings feststehen. Diese lassen sich als Vektor in einem n-dimensionalen Raum begreifen (vgl. Abb. 9).




Abb. 9: Zwei unterschiedliche Intervalltrainings (links) können durch charakteristische Merkmale beschrieben/generiert werden. Diese Merkmale können als Punkte (farbige Kreuze) in einem n-dimensionalen Raum (hier 3D) verstanden werden.

In der vorliegenden Studie wurde ein Trainingsgenerator implementiert, der mit einem 8-dimensionalen Merkmalsvektor arbeitet. Grundsätzlich ist dieser Generator frei austauschbar und so können beliebig viele Merkmale eines strukturierten Trainings einfließen.

Die Generierung einer Auswahl verschiedener Trainingseinheiten gemäß den Anforderungen aus der Belastungs-Sequenz stellt erneut ein Optimierungsproblem dar. Da dies die gleichen Charakteristika aufweist wie das in P/1 beschriebene, kann auch hier erfolgreich CMA-ES zur Optimierung angewendet werden. Es werden erneut fünf verschiedenartige optimierte Trainingsprofile generiert. Die Auswahl erfolgt auch hier durch Benutzerinteraktion.

### 5.1.5 Prototypische Umsetzung des SMPI-Zyklus

Ziel dieser Studie war es, die Umsetzbarkeit eines vollständigen SMPI-KI-Kreislaufs für den Anwendungsfall Trainingssteuerung im Radsport prototypisch zu demonstrieren. Hierzu wurden zunächst für jeden Teilschritt S/1, S/2, M/1, M/2, P/1 und P/2 verschiedene Methoden und Varianten der Implementierung gesichtet, evaluiert und schließlich die jeweils vielversprechendsten ausgewählt. Da die Schritte jeweils auf dem Ergebnis des vorangegangenen Schritts

aufbauen, können sie nicht vollständig voneinander entkoppelt betrachtet werden und stellen lediglich eine mögliche, exemplarische Realisierung dieses Use Case dar. Sobald in einem Schritt unterschiedliche Entscheidungen getroffen werden, wie beispielsweise eine unterschiedliche Wahl der Zielgröße des Systems, müssen die einzelnen Modellierungsschritte auf ihre inhaltliche Stringenz überprüft und ggf. angepasst werden.

Für die Validierung des vorliegenden Ansatzes wurde zudem eine hybride Nutzung von empirischen und simulierten Daten der Trainierenden angestrebt. Dafür wurden die empirischen Trainings- und Leistungsdaten in Übereinstimmung mit der gewählten Zykluslänge in 7-Tage-Blöcke aufgeteilt. Aus Sicht eines anstehenden Zyklus-Durchlaufs zu einem bestimmten Zeitpunkt der Studie kann somit eine zukünftige, empirische Stützstelle bezüglich der Leistungsfähigkeit in der Folgewoche als Trainingsziel verwendet werden. Auf dieser Basis werden schließlich konkrete Trainingsvorschläge generiert, die die empirischen Daten alternativ zu dem tatsächlich durchgeführten Training ergänzen. Durch die Nutzung dieser simulierten Daten kann die Schließung des KI-Kreises nachgeahmt werden und es ist möglich die bestehenden Daten mit den durch das KI-System generierten Daten vergleichend zu validieren.

### **5.1.5.1 Zusammenfassende Parameter- und Modellauswahl**

Zusammenfassend wurde in den einzelnen Schritten des Kreislaufs die in der folgenden Tabelle 3 voneinander abhängige Parameter- und Modell-Auswahl getroffen.

Tab. 3: Zusammenfassende Parameter- und Modellauswahl im Rahmen der vorliegenden prototypischen Umsetzung eines SMPI-KI-Kreislauf für den Use Case Trainingssteuerung im Radsport.

S/1	sekündliche Trainingsherzfrequenz und -belastung (Watt) aggregierte Trainingsdauer ober- und unterhalb der VT2
S/2	2. ventilatorische Schwelle (VT2, bestimmt aus mehreren Leistungsdiagnostiken unter Laborbedingungen) als Belastungswert (Watt)
M/1	Lineares HF-Modell basierend auf zwei exponentiell geglätteten Belastungswerten (30 sec, 500 sec), individualisiert auf Basis der bisherigen Trainingseinheiten (negativ exponentiell gewichtet gemäß dem Alter der Daten)
M/2	Antagonistisches Modell (PerPot DoMo; Eingabe: Trainingsdauer unter- und oberhalb der VT2 ( $T_{VT2+}$ , $T_{VT2-}$ ; Ausgabe: simulierte Leistungsfähigkeit), kalibriert mit den vergangenen Trainings- und virtuellen Leistungsdaten des jeweils aktuellen Zyklus-Durchlaufs, non-linear least-squares Optimierung mit Multistart-Suche
P/1	Fünf verschiedene 7-tägige per CMA-ES optimierte Belastungs-Sequenzen Auswahl durch Benutzerinteraktion
P/2	Parametrisierter Generator für strukturierte Trainings + CMA-ES zur Optimierung. Auf Basis der Auswahl aus P/1 werden fünf Trainingseinheiten (Belastungsprofile) berechnet, Auswahl durch Benutzerinteraktion

### 5.1.5.2 Beschreibung eines SMPI-KI-Zyklus

Ein Zyklus des KI-Systems beginnt mit der Erfassung und Verarbeitung der Trainings- und Leistungskennwerte (S/1 und S/2) in Bezug auf die trainierende Person für den vergangenen 7-Tages-Zyklus. Aus dem Verhältnis der Belastung und resultierenden Herzfrequenz passender Trainingseinheiten wird die virtuelle Leistungsfähigkeit berechnet (M/1). Nachdem auf Basis der vorliegenden Daten des aktuellen Zyklus eine optimierte Parametrisierung für das Trainings-Wirkungs-Modell aus M/2 erstellt wurde, dient die Modellierung aus M insgesamt als Input für das Planungsmodul P. Dieses generiert in Abhängigkeit der aus den empirischen Daten



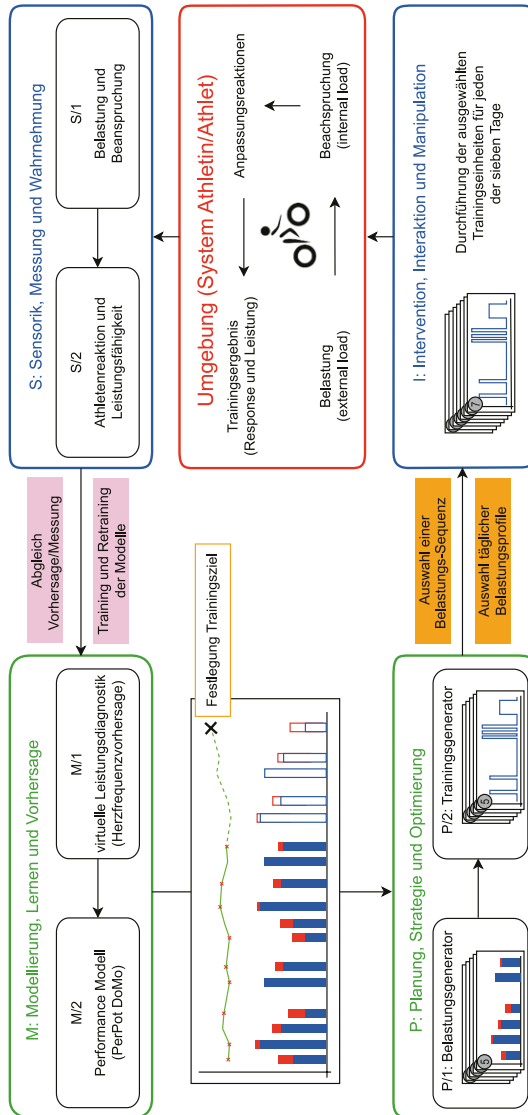


Abb. 10: Ausgestaltung des SMPI-KI-Kreislaufs inklusive Elemente der Benutzerinteraktion (orange hinterlegt) und kontextuellen Informationen (pink hinterlegt) für den Use Case Leistungssteuerung im Radsport. Das Trainingsziel (orange Umrandung) wird in der vorliegenden Umsetzung aus den empirischen Daten selbst abgeleitet, könnte aber theoretisch auch durch Nutzerinteraktion festgelegt werden.

extrahierten Leistung als Zielgröße für das Ende des aktuellen Zyklus eine Auswahl an qualitativ unterschiedlichen Belastungs-Sequenzen (P/1), die dann in einer Benutzerinteraktion zur Auswahl angeboten werden. Nach Auswahl einer konkreten Sequenz werden für jeden einzelnen Trainingstag mehrere qualitativ verschiedene strukturierte Trainingseinheiten generiert (P/2), die zur geplanten Belastung führen und somit im Optimalfall das Trainingsziel realisieren. Diese werden nun einerseits „trainiert“ und andererseits existiert für diese eine Vorhersage für den erwarteten Trainingseffekt. Dieser kann nun durch das System, mit dem in Schritt S gemessenen tatsächlichen Effekt verglichen und zum *retraining* der Modelle verwendet werden. Abbildung XYZ visualisiert diesen Ablauf inklusive der notwendigen Benutzerinteraktion.

### 5.1.5.3 Demonstrator

Um zu demonstrieren, wie Athleten und Athletinnen oder Trainer und Trainerinnen die vorgestellte KI-Schleife im Sinne eines sich wiederholenden Zyklus auch im praktischen Trainingsalltag anwenden können, wurde ein Demonstrator für ein Trainings-Unterstützungs-System umgesetzt. Dieser basiert auf einer interaktiven Weboberfläche, in der in einem Dialogfenster zunächst exemplarisch fünf verschiedene Trainingssequenzen vorgeschlagen werden, welche laut Vorhersage des Trainings-Wirkungs-Modells zum selben Leistungsziel führen sollen (vgl. Abb. 11).

Wurde eine vorgeschlagene Trainingssequenz ausgewählt, so wechselt das Dialogfenster zur Auswahl eines konkreten Trainings (vgl. Abb. 12). An dieser Stelle lassen sich die konkreten Trainingseinheiten für jeden Tag der ausgewählten Trainingssequenz anzeigen und auswählen. Hierbei kann für jeden Tag aus insgesamt fünf Vorschlägen eine Trainingseinheit ausgewählt werden.

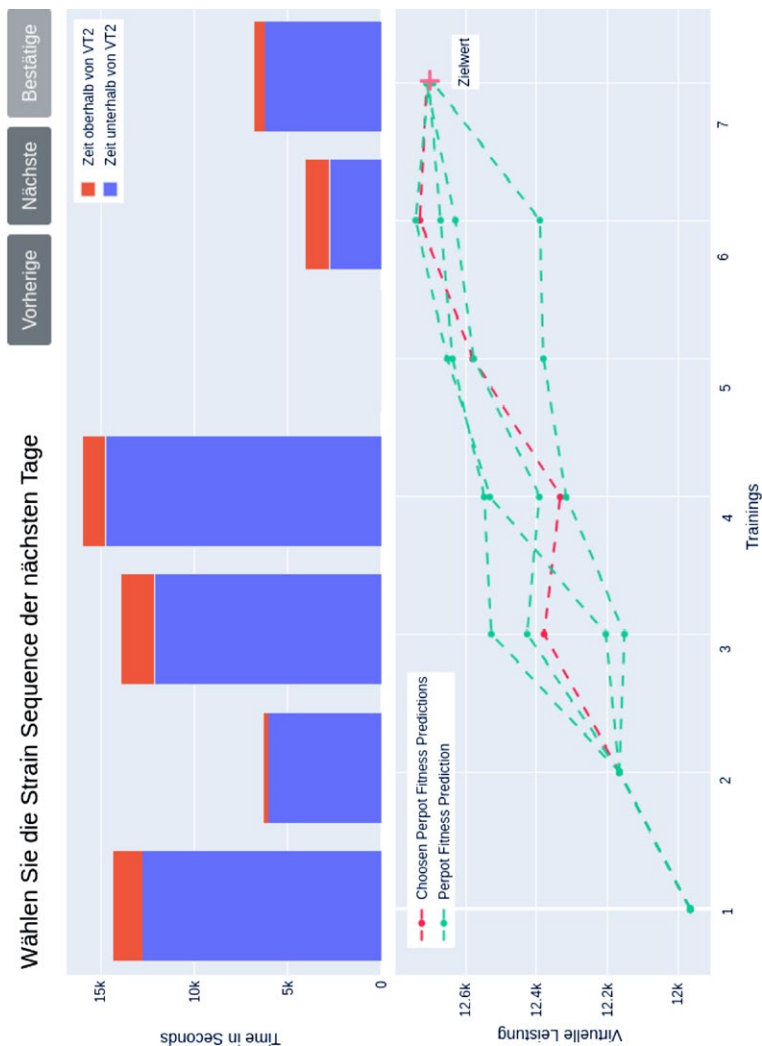


Abb. 11: In einem Dialogfenster wird die wöchentliche Trainingssequenz (im oberen Teil des Bildes als Balkendiagramm dargestellt) mit der hierzu erwartenden Leistungsentwicklung (im unteren Teil des Bildes als roter Liniengraph dargestellt) für einen konkreten Trainingsvorschlag gegenübergestellt. Die grünen Linien im unteren Teil des Bildes veranschaulichen die voraussichtliche Leistungsentwicklung für die restlichen vier Trainingssequenzen.




Abb. 12: Darstellung eines exemplarischen Workouts, welches eine vorgegebene Trainingsdauer ober- und unterhalb der VT2 für eine Trainingseinheit an einem Tag aus der bereits zuvor ausgewählten Trainingssequenz konkretisiert.




Abb. 13: Exemplarische Darstellung eines Saisonverlaufs, in dem das Training mit der Leistungsentwicklung gegenübergestellt wird. Hierbei stellen die nicht transparenten Säulen Trainingstage dar, an denen bereits trainiert wurde, wohingegen die transparenten Säulen die noch ausstehenden Trainingseinheiten darstellen. Analog dazu stellt die grüne durchgezogene Linie die Leistungsentwicklung dar, die dem bereits durchgeführten Training zugrunde lag, und die gestrichelte Linie die Leistungsentwicklung, die bei der Durchführung des noch ausstehenden Trainings zu erwarten ist. Mit den Kreuzen werden die einzelnen Fitnessziele in der Saison dargestellt.

Nachdem die konkreten Trainingseinheiten für jeden Tag ausgewählt wurden, wird die Auswahl der Trainingssequenz sowie der vorhergesagten Leistungsentwicklung an den bisherigen Saisonverlauf angehängen (vgl. Abb. 13). Nach Abschluss der geplanten Trainingswoche startet ein neuer Wochenzyklus, in dem das Leistungsziel, die hierzu erforderlichen Trainingssequenzen sowie die hierzu korrespondierenden konkreten Trainingseinheiten ausgewählt werden.

### 5.1.6 Diskussion und Ausblick

Die Realisation und prototypische Umsetzung des Use Case Trainingssteuerung im Radsport unter Nutzung des Konzepts eines SMPI-KI-Kreislaufs erfordert eine ganzheitliche Sicht auf die zugrundeliegenden Prozesse – sowohl aus informatischer als auch aus sportwissenschaftlicher Perspektive. Im Folgenden werden zuerst ausgewählte Aspekte der Modellbildung und die darin enthaltenen Herausforderungen und Entscheidungen skizziert, um die Komplexität und Interdependenzen zu verdeutlichen, dann allgemeinere Aspekte mit Bezug auf die gesamte Expertise thematisiert und schließlich mit einem kurzen Ausblick auf mögliche Anknüpfungspunkte abgeschlossen.

Der Bereich des maschinellen Lernens stellt grundsätzlich eine Vielzahl an anwendbaren Verfahren zur Verfügung (vgl. Kap. 3.2). Unvollständige Daten, Rauschen, intra- und interindividuelle physiologische Variabilität und die Unmöglichkeit einer vollständigen Modellierung der physiologischen Zusammenhänge bzw. Anpassungsprozesse legen dabei die Verwendung probabilistischer Lern- und Modellierungsverfahren nahe. Gleichzeitig müssen aber Echtzeitanforderungen aufgrund der stattfindenden Benutzerinteraktion eingehalten werden. Dies stellt besondere Anforderungen an die Zeit-Komplexität der Algorithmen. Moderne Quality-Diversity-Verfahren bieten in diesem Kontext die Möglichkeit einer erweiterten Einbindung der Nutzer und Nutzerinnen in den Auswahl-Prozess der Trainings (Hagg et al. 2018) und halten gleichzeitig durch die Verwendung von Surrogat-Modellen die Komplexität beherrschbar (Gaier et al. 2017b). Durch die Nutzung der vorlie-

genden Trainingsdaten, könnten Trainingseinheiten vorgeschlagen werden, die den vergangenen Einheiten ähneln oder gerade diesen unähnlich sind, so dass sowohl die Präferenzen der Trainierenden bedient als auch Anregungen zu alternativen Trainingsmethoden gegeben werden könnten.

Im Hinblick auf die tatsächlich eingesetzten Verfahren der KI und die verwendeten Modelle kann zunächst festgestellt werden, dass diese geeignet waren, um das Projektziel umzusetzen. Inwiefern die Güte von Approximation und Vorhersage noch weiter verbessert werden kann, hängt letztendlich von der konkreten Auswahl der Verfahren sowie deren Validität in jedem einzelnen Schritt der KI-Schleife zusammen. Für die Modellierung von Trainingswirkungen innerhalb und zwischen Trainingseinheiten wurde in der vorliegenden Realisierung aus Sicht der Informatik und Sportwissenschaft lediglich eine einzige mögliche Auswahl an Modellen, Optimierungsalgorithmen, Rand- und Rahmenbedingungen, Trainings- und Leistungsparametern und vielem mehr getroffen. Beispielsweise stellt die Modellierung der tagesübergreifenden Trainingswirkung durch das PerPot DoMo unter Nutzung der Dauer in verschiedenen Intensitätsbereichen und der virtuellen Leistungsfähigkeit eine sportart- und situationsspezifische Auswahl dar. In der trainingswissenschaftlichen Forschung werden eine Vielzahl an möglichen Input-Output-Kombinationen für alle möglichen sportlichen Kontexte diskutiert (u. a. Bourdon et al. 2017, Meyer et al., 2020). Die virtuelle Leistungsfähigkeit als Zielgröße der KI-Schleife, die auf Basis der Belastungs- und Herzfrequenz-Verläufe der durchgeführten Trainingseinheiten berechnet wurde, sollte jedoch in Abwägung möglicher Alternativzugänge, hinsichtlich ihrer Überlegenheit, noch kritisch geprüft werden. Ähnliches gilt auf methodischer und inhaltlicher Ebene auch für die Bereiche P/1 und P/2. Trainingsvorgaben in Form eines Belastungsprofils werden beispielsweise in der Praxis des Radsports oftmals genutzt, wohingegen sich spezifische Merkmale und konkrete Ausprägungen (8-dimensionaler Merkmalsvektor, vgl. Abschnitt P/2) vermutlich von Trainingsgruppe zu Trainingsgruppe und auch von Standort zu Standort unterscheiden, und an individuelle Bedürfnisse angepasst werden müssen. Die Validierung und Begründung der ausgewähl-

ten Methoden und zugrundeliegenden Annahmen bezüglich der kausalen Beziehungen innerhalb und zwischen den einzelnen KI-Schritten ist eine ständige Begleitaufgabe in der Umsetzung eines SMPI-Kreislaufs.

Grundsätzlich gilt es insbesondere die Small-Data-Problematik sowie die sportartspezifischen, institutionellen Bedingungen, unter denen Daten in der Trainingspraxis erhoben und verarbeitet werden können, im Blick zu behalten. Die Voraussetzungen im Leistungssport unterscheiden sich zudem von den Anwendungsfeldern im Fitness-, Freizeit- oder Gesundheitssport, sodass individuelle Anpassungen an der Ausgestaltung der KI-Schleife vorgenommen werden müssen. Für die Akzeptanz und tatsächliche Nutzung in der Sportpraxis, insbesondere im Spitzensport, ist nicht zuletzt die Datensicherheit und Transparenz der Datenerhebung und -verarbeitung von größter Bedeutung. Schließlich wären umfassendere Studien und Exploration möglicher Realisierungen inklusive der für die Praxis relevanten und gewünschten sportartspezifischen Möglichkeiten der Nutzerinteraktion wünschenswert, um die im Rahmen dieses Projekts gesammelten Erfahrungen gewinnbringend zu erweitern. Dafür ist die Abstimmung zwischen betreuendem Personal, Experten und Expertinnen aus der Wissenschaft und Praxis, sowie den Trainierenden selbst von großer Bedeutung.

## 5.2 Wettkampfdiagnostik in den Sportspielen

Nachfolgend soll aufgezeigt werden, wie ein KI-System zur Spielanalyse am Beispiel Fußball umgesetzt werden könnte. Der Blick wird hierbei auf ein leistungsdiagnostisches Anwendungsszenario gerichtet, d. h. die Analyse der Leistungsrelevanz taktischer Verhaltensweisen mit dem Ziel, die zukünftige Spielleistung zu optimieren (Winter & Pfeiffer, 2020). KI könnte hier erfolgversprechend eingesetzt werden, um aus verschiedenen Sensordaten automatisiert taktische Verhaltensweisen zu identifizieren, deren Beitrag



zur Spielleistung und/oder dem Spielerfolg zu bestimmen und anschließend Empfehlungen zur Optimierung der Taktik abzuleiten.

**S:** Sensorik, Messung und Wahrnehmung: In diesem Teilschritt geht es zunächst darum, intelligente Methoden für eine rückwirkungsfreie Erfassung relevanter Daten in Echtzeit einzusetzen. Grundsätzlich lässt sich hierbei zunächst unterscheiden, ob es sich um Daten eines Typs (unimodal), wie beispielsweise Positionierungsdaten im zweidimensionalen Raum, oder eine Kombination verschiedener Datentypen (multimodal), beispielsweise durch Ergänzung von Fitnessdaten (z. B. Atem- oder Herzfrequenz), handelt. In den letzten Jahren konnten, angetrieben durch den technologischen Fortschritt auf dem Gebiet der Sensorik (u. a. in Wearables) und der informatischen Modelle (u. a. maschinelles Sehen), vielversprechende innovative Ansätze zur Erfassung von Verhaltensdaten entwickelt werden (vgl. Kap. 3.1).

**M:** Modellierung, Lernen und Vorhersage: Das übergeordnete Ziel dieses Teilschritts besteht darin, aus den in S erfassten Daten die relevanten Informationen zu generieren. Bezogen auf das genannte Anwendungsbeispiel gilt es, geeignete Methoden zu finden bzw. zu entwickeln, um das taktische Verhalten zu modellieren. Für das Sportspiel Fußball wäre hierbei u. a. zu fordern, dass eine valide Differenzierung nach individual-, gruppen- und mannschaftstaktischen Verhaltensweisen (Aktionen) gelingt. Dies ist von zentraler Bedeutung, weil der fußballspezifischen Trainings- und Wettkampfanalyse diese Strukturierung zugrunde liegt und die erforderliche Akzeptanz seitens der Sportpraxis (vgl. Kap. 4) hierdurch gesichert bzw. erhöht werden kann. Je nach Datentyp lassen sich zur Modellierung des taktischen Verhaltens im Fußball die in Kapitel 3.2 beschriebenen Methoden einsetzen. Besonders hervorzuheben sind Modelle aus den Bereichen Deep Learning und Transferlernen. Letzteres bietet den Vorteil, dass zunächst über eine Zusammenführung von Daten vieler Teams eine große Datenmenge erzeugt und modelliert werden kann. Die Parameter der so generierten Meta-Modelle lassen sich anschließend an die Daten eines Teams anpassen, wodurch eine teamspezifische Abbildung des taktischen Verhal-

tens möglich wird. Insgesamt sind bei der Umsetzung des Teilschritts M die in Kapitel 3 angesprochenen Bereiche zu beachten, insbesondere die Erklärbarkeit (Kap. 3.2.3), Robustes Lernen (Kap. 3.2.4) und die Fehler- und Risikoerkennung (Kap. 3.2.6). Auf dem Gebiet der Modellierung taktischen Verhaltens auf der Basis von Positionierungsdaten wurden in den letzten Jahren vor allem im Fußball erfolgversprechende Ansätze vorgestellt. Allerdings wird bei einer genaueren Betrachtung deutlich, dass die Ergebnisse aus Sicht des Spitzensports vielfach zu undifferenziert im Hinblick auf die Ableitung konkreter Handlungsziele/-empfehlungen sind. Dies ist vermutlich auch der Grund dafür, dass die in der Wissenschaft vielfach diskutierten Möglichkeiten bislang in der spitzensportlichen Praxis kaum angekommen sind.

- P:** Planung, Strategie und Optimierung: Aus Sicht der Praxis ist dies der wohl interessanteste Teilschritt einer KI-Anwendung. Im Zentrum steht die Anwendung von Modellen zur Optimierung des taktischen Verhaltens im Hinblick auf die Spielleistung oder den Spielerfolg. Die sportwissenschaftliche Forschung hat sich hier bislang vor allem auf die Bestimmung der Leistungsrelevanz taktischer Verhaltensweisen konzentriert, wobei mehrheitlich auf lineare statistische Methoden (häufig univariate Verfahren) zurückgegriffen wurde. Eine genaue Betrachtung der verschiedenen Studien verdeutlicht, dass strukturorientierte Modelle dominieren, d. h. die zentralen Strukturelemente des Spiels abgebildet werden. Der Verhaltensstrom, also die prozessuale Verbindung der Strukturelemente, und die Wechselbeziehung der Elemente untereinander bleiben im Modell unberücksichtigt. Die jedoch folgenreichste Reduktion des Originals „Fußballspiel“ besteht darin, dass der Interaktionsprozess zwischen den Teams modellseitig nicht abgebildet wird. Erste Ansätze einer prozessorientierten Modellbildung erfolgten mit Markov-Ketten z. B. im Tennis (Lames, 1991), Tischtennis (Pfeiffer, Zhang & Hohmann, 2010) oder Handball (Pfeiffer, 2005). Allerdings wurde das Spielverhalten hierbei in nur einem Prozess und mit sehr geringer struktureller Auflösung erfasst, so dass die Ergebnisse für die Ableitung konkreter Handlungsempfeh-

lungen nur eingeschränkt zulassen. Um zukünftig auf diesem Gebiet weiter voranzukommen, könnte der Einsatz innovativer Methoden der KI-Forschung, wie sie in Kapitel 3.3 beispielsweise zur Lösungsdiversität, zu multiplen Kriterien oder zur robusten Optimierung beschrieben sind, einen substanziellen Mehrgewinn darstellen. Allerdings wird auch hier die Güte der KI-Anwendung davon abhängen, inwieweit sich die für die Spielleistung bzw. den Spielerfolg relevanten Originalattribute des Spiels in den Modellen widerspiegeln.

- I: Intervention, Interaktion und Manipulation: Abschließend gilt es die vom KI-System empfohlenen taktischen Verhaltensweisen im Wettkampf umzusetzen. Um die Spieler und Spielerinnen hierauf vorzubereiten, können innovative Methoden wie in Kap. 3.4.2 und 3.4.3 beschrieben, unterstützend eingesetzt bzw. entwickelt werden. Das Wettkampfverhalten wird dann wiederum, wie in Teilschritt S erläutert, erfasst und dient als Ausgangspunkt der weiteren KI-Teilschritte.

### 5.3 Leistungsdiagnostik in multi-technischen Individualsportarten

Die zentrale Aufgabe der trainingswissenschaftlichen Leistungsdiagnostik besteht darin, die sportliche Leistung zu strukturieren. Dies beinhaltet nicht nur die Beschreibung leistungsrelevanter Faktoren, sondern darüber hinaus die genaue Quantifizierung des Einflusses dieser Größen. Insbesondere bei multitechnischen Sportarten bzw. Disziplinen mit einem hohen Grad an Kompensationsmöglichkeiten ergeben sich hier aufgrund des Komplexitätsüberhangs vielfältige Probleme, zu deren Lösung die KI einen wesentlichen Beitrag leisten könnte. Nachfolgend soll dies als Idee am Beispiel des leichtathletischen Mehrkampfs aufgezeigt werden.

- S: Sensorik, Messung und Wahrnehmung: Auf Grundlage bereits in der Sportpraxis erprobter und wissenschaftlich fundierter Leistungsstrukturmodelle für die einzelnen Disziplinen werden zunächst die leistungsrelevanten Kenngrößen der sport-

lichen Leistungsfähigkeit (konditionelle Leistungsvoraussetzungen, Technikmerkmale usw.), die Wettkampfergebnisse der Einzeldisziplinen sowie weitere leistungsrelevante Parameter der Wettkampfleistung (z. B. Teilzeiten, Schrittlängen- und -frequenzen, Anlaufgeschwindigkeiten, biomechanische Merkmale usw.) erfasst. Für die Erhebung derartiger Daten existiert bereits eine Vielzahl unterschiedlicher Methoden. Dennoch besteht auch hier weiterer Entwicklungsbedarf, beispielsweise auf dem Gebiet der automatisierten und prozessualen Datenerfassung (u. a. Bilderkennung). Hier sind die in Kapitel 3.1 beschriebenen Methoden noch nicht umfassend für den Einsatz im Kontext des hier skizzierten Anwendungsszenarios im Spitzensport gesichtet worden.

- M:** Modellierung, Lernen und Vorhersage: In diesem Teilschritt besteht die zentrale Aufgabe darin, den Zusammenhang zwischen den Merkmalen der sportlichen Leistungsfähigkeit, der Wettkampfleistung in den Einzeldisziplinen (einschl. weiterer Kenngrößen wie z. B. biomechanischer Merkmale) und der Gesamtleistung (Punkte). Eine besondere Herausforderung stellt hierbei die gemeinsame Analyse von Daten unterschiedlicher Kategorien und Mengen dar. Aus dem vielfältigen KI-Methodeninventar (Kap. 3.2) gilt es, geeignete Methoden zu identifizieren oder bestehende weiterzuentwickeln, mit denen diskrete und stetige (prozessuale) Daten in Kombination modelliert werden können. Hierbei ist unbedingt die Expertise der Sportpraxis einzubeziehen.
- P:** Planung, Strategie und Optimierung: Während in einigen Bereichen der ersten beide KI-Teilschritte bereits wissenschaftliche Erkenntnisse und sportpraktische Erfahrungen für den Mehrkampf der Leichtathletik vorliegen, kann im Teilschritt P kaum auf bisherige Forschungsarbeiten aufgebaut werden. Im Mittelpunkt steht hier die Ableitung von Strategien zur Optimierung des Gesamtergebnisses (Mehrkampf-Punkte) mit Hilfe von Methoden der KI (vgl. Kap. 3.3). Unter Berücksichtigung der Datentypen, -mengen und -qualitäten sind entsprechende Methoden zu wählen, wobei im skizzierten Szenario des Mehrkampfes multiple Kriterien (Kap. 3.3.3) oder die robuste Optimierung (Kap. 3.3.5) hilfreiche Ansätze bieten.

- I: Intervention, Interaktion und Manipulation: Die von der KI bereitgestellten („empfohlenen“) Optimierungsstrategien gilt es durch entsprechende Trainingsmaßnahmen vorzubereiten und im Wettkampf umzusetzen. Unterstützend können hierbei die in Kapitel 3.4 beschriebenen Methoden eingesetzt werden.



# Handlungsempfehlungen

6





Nachdem wir uns mit den Anwendungsbereichen und Methoden der KI im allgemeinen, möglicher Synergien für den Spitzensport sowie konkreten Anwendungsszenarien (Use Cases) auseinandergesetzt haben, werden nachfolgend hieraus Handlungsempfehlungen abgeleitet. Die Empfehlungen werden in sechs Themenbereiche strukturiert, beginnend mit der Daten- und Methodenlage (Kap. 6.1) über die vier Teilschritte eines KI-Systems (Kap. 6.2 bis 6.5) bis hin zur Wissenschaftsorganisation (Kap. 6.6).

## 6.1 Daten- und Methodenlage

Die Datenlage ist in den verschiedenen Sportarten nicht homogen, so dass sich die häufig zwar ähnlich gelagerten Probleme oder Fragestellungen nicht mit einer einzigen KI-Methodik abdecken lassen. Beispielsweise lassen sich Aktivitäten über Methoden des Deep Learnings nur dann erkennen, wenn größere Datenmengen zur Verfügung stehen. Dies ist jedoch insbesondere im Spitzensport nicht immer der Fall. Für jede KI-Anwendung muss zunächst gesondert die Datenlage genau beschrieben und eingeordnet werden, um zu beurteilen, welche Methoden anwendbar sind bzw. sich entsprechend der Datenlage anpassen lassen. Dabei sollte nach der Datenmenge und der Datenqualität (welche Zielwerte wie z. B. Klassifikationsdaten sind enthalten) unterschieden werden. Das Angebot von freien und offenen Datensammlungen und Methoden aus dem Spitzensport würde innerhalb der KI-Gemeinschaft auf positive Resonanz stoßen; die spezifischen Eigenschaften von Sportdaten könnten so einfacher in die Entwicklung robuster Methoden der KI fließen. Dabei könnten auch Datensätze mehrerer Sportler und Sportlerinnen zusammengeführt werden, um bestimmte Problemstellungen mit Methoden der KI lösen zu können. Gleichzeitig sollte im Hinblick auf die Genauigkeit und Generalisierungsfähigkeit von KI-Systemen versucht werden, KI-Ansätze zu nutzen oder zu entwickeln, die mit kleinen Datensätzen arbeiten können.

Im Spitzensport werden häufig Daten mit verschiedenen Sensoren erhoben. Bei der Fusion mehrerer Sensordaten bietet

Deep Learning bei größeren Datenmengen zwar eine Alternative, aber es sollten auch die klassischen Methoden berücksichtigt werden. Sollten beispielsweise bestimmte Korrelationen und Kausalmechanismen bekannt sein, bieten sich klassische Modelle an und sollten auch zur Anwendung kommen.

Bei großen Mengen an unqualifizierten Daten sollten Methoden des Unsupervised Learning daraufhin untersucht werden, ob diese auch im Bereich der Sportdaten als Teilersatz des Modelltrainings eingesetzt werden können.

Viele Individualsportarten sind dadurch gekennzeichnet, dass lediglich ein kleiner Personenkreis die Daten generiert. Durch pseudonymisiertes oder anonymisiertes föderiertes Lernen könnten auch hier komplexere Methoden angewendet werden, indem die Modelle zunächst in anderen Sportbereichen vortrainiert und dann transferiert werden. Eine weitere Möglichkeit, mit dem Small Data-Problem umzugehen besteht darin, kleine Datensätze durch die gemeinsame Nutzung zu größeren Datensätzen zu verknüpfen. Dadurch können auch Lernmethoden eingesetzt werden, welche größere Datensätze benötigen. Auch hier ist auf die Datensicherheit und Privatsphäre im Rahmen des Konkurrenzgedankens im Sport zu achten.

Solche Ansätze, die speziell für Small Data bereitgestellt werden, z. B. Surrogatassistentz, Transferlernen und spezifische „Small Data Modelle“, aber auch klassische Methoden des maschinellen Lernens, haben unterschiedliche Strategien, mit den Daten umzugehen. Vor dem Hintergrund der jeweiligen Frage- oder Zielstellung ist zunächst ein weiter Blick auf die unterschiedlichen Ansätze notwendig, da diese sich oft in den Anforderungen und Anwendungsvoraussetzungen deutlich voneinander unterscheiden.

Um den Einsatz von KI zur Unterstützung der Aufgaben im Spitzensport zukünftig weiter voranzubringen, sollten Wissenschaft und Sportpraxis gemeinsam eruieren, welche Daten aktuell erhoben und welche Methoden zu deren Analyse verwendet werden. In einem nächsten Schritt sind konkrete Ziele für eine KI-Anwendung in den jeweiligen Szenarien zu erarbeiten, damit

anschließend eine entsprechende Strategie zu deren Erreichung entwickelt werden kann. Letzteres beinhaltet insbesondere Fragen der Digitalisierung im Spitzensport (Datenerfassung, -organisation und -speicherung; Standards der Datenerfassung usw.), weil KI das Vorhandensein digitaler Daten voraussetzt.

## 6.2 S: Sensorik, Messung und Wahrnehmung

- › Die spezifischen Probleme, die vor allem die Portabilität der Modelle (Training und Vorhersage) reduzieren, müssen technisch oder methodisch abgefangen werden. So muss beachtet werden, in welchen Situationen Wearables überhaupt anwendbar sind.
- › Der Einsatz von Wearables hängt zum einen davon ab, inwieweit diese rückwirkungsfrei in den Bereichen Training und Wettkampf getragen werden können. Für den Einsatz im Wettkampf ist darüber hinaus zu klären, welche Geräte im Einklang mit dem Regelwerk genutzt werden können.
- › Durch eine Kombination von z. B. Kameradaten und Wearables könnten beispielsweise im Bereich der Sportspiele die Positions- und Fitnessdaten zusammengeführt und gewinnbringend im Rahmen der Taktikplanung eingesetzt werden. So wäre es z. B. möglich, Strategien zu entwickeln, die Gegnerin oder Gegner bzw. die gegnerische Mannschaft körperlich mehr herausfordern als die Spielerin oder den Spieler selbst bzw. die eigene Mannschaft. Die Fusion solcher Sensornetzwerke bietet eine Reihe an Kombinationsmöglichkeiten und somit Anwendungsfällen, die einen Wettbewerbsvorteil darstellen könnten. Weiterhin lässt sich im Spitzensport durch die Kombination mehrerer Sensor-

modalitäten die Genauigkeit der Messungen und damit die Vorhersagegüte erhöhen.

- › In Sportarten mit mehreren Teilnehmenden gilt es Bewegungsmodelle zu entwickeln, die bei der Verfolgung einzelner Sportler und Sportlerinnen aufgrund von Okklusionen durch andere beteiligte Personen eine Weiterverfolgung ermöglichen.
- › Die Realzeit- und Portabilitätsanforderungen im Spitzensport führen möglicherweise zu einer Verwendung weniger leistungsstarker KI-Methoden. Dies muss unter Umständen in Kauf genommen werden. Der Trade-Off zwischen Leistung und Portabilität sollte zukünftig weiter erforscht werden. Es kann auch für rechnerisch aufwändigere Methoden auf GPUs oder dedizierte Hardware gesetzt werden. Hier sind der Stromverbrauch und die Portabilität abzuwägen.

Auf dem Gebiet der Sensorik, und damit der Messung und Wahrnehmung der Umgebung, ist aktuell sicherlich der größte Fortschritt zu beobachten, so dass sich viele der für den Spitzensport relevanten Daten heutzutage recht gut erfassen lassen. Dennoch muss auch im Fall von bereits etablierten und routinemäßig eingesetzten Datenerhebungsmethoden zunächst vor dem Hintergrund des Anwendungsszenarios und der Zielstellung beurteilt werden, ob sowohl die Erfassungssysteme als auch die hiermit erzeugten Daten für die Implementierung in eine entsprechende KI geeignet sind. Hierbei wäre es hilfreich, gemeinsam mit der Sportpraxis verbindliche Standards zu erarbeiten, um für datenintensive Modellierungsansätze (vgl. u. a. Kapitel 3.2 und 6.1) die erforderlichen Voraussetzungen zu schaffen.

## 6.3 M: Modellierung, Lernen und Vorhersage

- › Die Erklärbarkeit von Modellen kann insbesondere in der Anwendung im Spitzensport von zentraler Bedeutung sein, denn nur hiermit lassen sich die beteiligten Personengruppen (Sportler und Sportlerinnen, Trainerschaft, medizinisches oder sonstiges Personal) davon überzeugen, dass die Modellvorhersage auch in Zukunft und in unerwarteten Situationen nutzbar bleiben und nicht zu erhöhten Risiken führt. Außerdem sollte die Validierung, aber auch die laufende Neubewertung der Systemleistung, im Vordergrund stehen. Lernende Modelle tun eben das: sie lernen, sich anzupassen. Somit muss auch die Systemleistung, die sich anpasst, neu bewertet werden.
- › Die Transparenz und Erklärbarkeit von Modellen des maschinellen Lernens können auch im Spitzensport beispielsweise mithilfe von generativen Modellen erhöht werden. Generative Modelle können z. B. im Training für die Erkennung unüblicher Bewegungen, für das Beschreiben und Erzeugen von Bildern für die Trainingsanalyse und -synthese und für die Integration unterschiedlicher Sportdomänen eingesetzt werden.
- › Ein weiterer Schwerpunkt bei der Anwendung von KI im Spitzensport sollte bei der Entwicklung von robusten Methoden liegen. In solchen Fällen, in denen die Daten aus dem Spitzensportbereich verrauscht oder fehlerhaft sind, können robuste Modelle auch auf eingeschränkten Datenmengen trainiert werden, wenn Daten mit generativen Modellen künstlich erzeugt werden.
- › Bei der Vorhersage sollte die Verwendung von statistischen „Grey-Box“-Modellen (z. B. Gaußprozessregressionsmodelle) immer als Alternative untersucht werden. So kann mit dem Konfidenzintervall einer Vorhersage die Aussagekraft von

Modellen unterstützt und relativiert werden. Vor allem in Grenzfällen sollte die Vertrauenswürdigkeit des Modells (Modellkonfidenz) für die Risikovermeidung immer berücksichtigt werden. Auch bei Sportarten mit größeren Datenmengen können Gaußprozessregressionsmodelle eingesetzt werden.

- › Die Fehler- und Risikoanalyse gehört zum sportwissenschaftlichen Alltag. Es ist daher zu empfehlen, dass bei der Modellierung immer ein Experte involviert wird. Auch sollte die Evaluierung von automatisierten Methoden zur Modellfindung im Nachgang eines Projekts mithilfe von Experten durchgeführt werden.

In diesem Teilschritt der KI bestehen derzeit noch die größten Herausforderungen für die Umsetzung eines KI-Systems in der leistungssportlichen Praxis. Zwar wurden zu einzelnen Handlungsfeldern des Spitzensports bereits konkrete Modellansätze in die wissenschaftliche Diskussion eingebracht (z. B. zur simulativen Trainingswirkungsanalyse) oder lassen sich derartige aufgrund elaborierter Theorien zeitnah entwickeln, jedoch fehlen bislang Überlegungen dahingehend, wie sich diese integrativ verbinden und in einem KI-System umsetzen (implementieren) lassen. Hier besteht die zukünftige Aufgabe darin, den Bestand an bereits vorliegenden Modellen, an wissenschaftlichen Erkenntnissen und an sportpraktischen Erfahrungen vor dem Hintergrund eines sportpraktisch relevanten Anwendungsfalls zusammenzutragen und im Hinblick auf die Entwicklung einer entsprechenden KI-Anwendung zu prüfen. Ein wichtiger Aspekt hierbei wird sein, wie mit den zum Teil verrauschten und/oder fehlerhaften Daten umzugehen ist und ob sich die Datenqualität durch eine bessere Standardisierung bei der Datenerfassung erhöhen lässt.

## 6.4 P: Planung, Strategie und Optimierung

- › Die Akzeptanz von KI-Methoden kann durch das Angebot einer Vielfalt an Lösungen erhöht werden, wenn diese Vielfalt gut dargestellt werden kann. Die Verknüpfung mehrerer Kriterien, wie z. B. Leistung und Zeiteffizienz, kann durch Optimierungsmethoden berücksichtigt werden. So können Lösungen wie Trainingspläne als sogenannte Trade-Offs dargestellt werden, was die Interaktion zwischen KI und Trainerschaft/Sportler und Sportlerinnen und somit die Akzeptanz von KI erhöht.
- › Dateneffiziente online Optimierung kann mit Hilfe von surrogatassistierten Methoden eine potenziell neuartige Interaktion zwischen KI und Sportler und Sportlerin ermöglichen. Die Interaktionsschleife, die so entsteht, kann Modelle potenziell schnell individualisieren, indem die KI solche Vorschläge macht, die von der Sportlerin oder vom Sportler ausgeführt werden. Es entsteht eine Rückkopplungsschleife, in der die Trainingsdaten und -ergebnisse zurück in das Modell geführt werden können. So entwickeln Sportler und Sportlerin und KI zusammen eine bestmögliche Strategie. Hierbei ist jedoch zu beachten, dass die von der KI gemachten Vorschläge in trainingssicheren Bereichen liegen.
- › Die Robustheit von Optimierungslösungen ist für den Spitzensport ein wichtiger Faktor und sollte immer betrachtet werden. Nur weil ein Trainingsplan, der auf Basis bestimmter Daten gefunden wurde, gut funktioniert, bedeutet dies nicht, dass der Plan auch in Zukunft in einer sich ändernden Umgebung eine hohe Qualität aufweist.
- › Die Verwendung einer KI erlaubt es, bei der Optimierung von Plänen und Strategien neuartige Lösungen zu finden. Die Erkundung neuer und die Ausbeutung bewährter Lösungen bestimmen eine Parametrisierungsdimension, die es Trainer und Trainerin sowie Sportler und Sportlerin erlauben,

systematisch Chancen und Risiken miteinander abzuwägen.

- › Für Sportarten, welche mit begrenzten finanziellen Möglichkeiten operieren und größere Projekte nicht umsetzen und/oder größere Softwareprodukte nicht kaufen können, sollten Ansätze favorisieren, bei denen die KI-Teilschritte **S**, **M** und **P** direkt miteinander verknüpft eine Lösung darbieten.

Insbesondere dieser Teilschritt der KI erfordert eine enge Zusammenarbeit zwischen Sportwissenschaft, Sportinformatik und Sportpraxis. In der Sportpraxis muss eine Offenheit und Bereitschaft zur Implementierung innovativer Ansätze und Modelle in den Trainingsalltag vorliegen. Dies schließt den Willen ein, an den KI-Lösungen zu arbeiten, d. h. diese zu evaluieren und permanent weiterzuentwickeln (zu verbessern), auch dann, wenn erste Versionen nicht den gewünschten Nutzen bzw. die erhoffte Unterstützung bringen.

## 6.5 I: Intervention, Interaktion und Manipulation

- › Die Akzeptanz von KI kann bei Sportlern und Sportlerinnen und Trainer und Trainerinnen erhöht werden, wenn die Methodik der KI integrativ – d. h. interaktiv und transparent – wirkt. Die Interaktion zwischen Trainer/Trainerin und Sportler/Sportlerin mit der KI kann hier einen wesentlichen Unterschied machen. Wenn die Algorithmik progressive und innovative Vorschläge macht, welche jedoch im üblichen Risikorahmen liegen, so kann die Schleife geschlossen werden. Hierbei sind Innovation und Verletzungsrisiko abzuwägen.
- › Die Entwicklung der im Spitzensport eingesetzten Wearables ist meistens produkt- und technologiegetrieben, statt aus Nutzersicht entwickelt. Es sollte hier der Mut



aufgebracht werden, den Entwicklungsprozess umzudrehen und die Bedürfnisse der Sportpraxis voranzustellen. Die Anbindung an breitere IoT-Ökosysteme, die Erforschung der Effekte von Wearables auf die Trainingspraxis, Smart Clothing und die Entwicklung von Geräten, die über den Gebrauch durch den durchschnittlichen Nutzer hinausgehen (Stichwort: Individualisierung), sind Forschungsrichtungen, die weiterverfolgt werden sollten. Extrinsisches Feedback kann über drei Hauptmodalitäten erfolgen (visuell, auditiv und haptisch) und ist je nach Sportart und den vorliegenden Gegebenheiten zu spezifizieren. Sprachinterfaces sind durch die Entwicklungssprünge der letzten zehn Jahre auch im Spitzensport längst angekommen und sollten weiterentwickelt werden.

- › Um die Transparenz und das Verständnis und somit die Akzeptanz von KI-Systemen zu vergrößern, muss immer die Visualisierung von Ergebnissen so informativ, aber auch effektiv wie möglich gestaltet werden. Hier können unter anderem Dimensionsreduktionsmethoden behilflich sein, wenn komplexe Daten oder Optimierungsergebnisse vermittelt werden müssen. Die Verwendung von generativen Modellen zur Visualisierung hochdimensionaler Daten und Optimierungsergebnisse kann hier äußerst hilfreich sein. So können die User aus dem Bereich des Spitzensports ein besseres Verständnis für die Daten und Ergebnisse entwickeln.
- › Virtual und Augmented Reality erlauben eine Rückkopplung zwischen KI und Sportlern und Sportlerinnen unter beherrschbaren und änderbaren Umgebungsbedingungen (Zuständen). Die Akzeptanz von Feedbacksystemen im Spitzensport kann durch Augmented Reality erhöht werden. Es kann bei der Verwendung von simulierten Umgebungen eine auf realen Daten basierte Interaktion und Adaption stattfinden. Die Skizze ist als handwerkliches Werkzeug auch im Spitzensport von Bedeutung, wenn aus der Skizze eine Simulation automatisch erzeugt wird. Diese Simulationen

lassen sich zur Unterstützung in das Training integrieren.

Während die Wissenschaft in enger Absprache mit der Sportpraxis für die Modellentwicklung verantwortlich ist, sind seitens der Sportpraxis zum einen die technischen Voraussetzungen zu schaffen, um die mittels KI generierten Handlungsempfehlungen in den Trainingsalltag implementieren zu können. Zum anderen muss seitens der Sportpraxis die Akzeptanz von KI und damit die Bereitschaft, gemeinsam mit der Wissenschaft innovative Ansätze zu entwickeln, zu erproben und weiterzuentwickeln, sichergestellt werden.

## 6.6 Allgemeine Empfehlungen für die Forschungsförderung

Die Entwicklung einer Sport-KI-Community und die spezifische Förderung Community-getriebener Veranstaltungen kann das gegenseitige methodische Verständnis verbessern. Ausschreibungen und Veröffentlichungen zur Weiterentwicklung der KI im Spitzensport sollten beiden Gruppen, sowohl der Sportwissenschaft als auch KI, gerecht werden und diese miteinander verknüpfen.

Damit der Spitzensport von den rasanten Entwicklungen auf dem Sektor der KI zukünftig profitieren kann, ist die Nutzung frei zugänglicher Software anzuraten, insbesondere im Zusammenhang mit öffentlich geförderten Projekten.

Bei der Entwicklung von Methoden und Anwendungen im Spitzensportbereich sollte auf die immer größer werdende Relevanz von Methoden und Techniken, welche die Privatsphäre schützt, geachtet werden.

Zuletzt empfehlen wir, die vorliegende Arbeit öffentlich zur Verfügung zu stellen. Hierbei sollten die in diesem Bericht von den Projektnehmern zitierten Übersichtsartikel gelesen werden, da auf eine detaillierte Ausführung der zitierten Arbeiten bewusst verzichtet wurde.

# Abschließende Beurteilung von KI im Spitzensport



Nachfolgend werden die Potenziale aber auch die Risiken des Einsatzes von KI im Spitzensport sowie der Grad der Anwendbarkeit eingeschätzt. Diese Betrachtung erfolgt in Orientierung an die Teilschritte der KI von der Sensorik bis zur Intervention, wobei jeder Schritt den jeweils vorausgehenden beinhaltet (Abb. 14). Im ersten Teilschritt Sensorik werden relevante Informationen der Umgebung erfasst (gemessen, wahrgenommen). Hier steht der Sportpraxis für die routinemäßige Anwendung bereits ein breites Spektrum an Messsystemen zur Verfügung, die mit geringem Risiko im spitzensportlichen Handlungsfeld eingesetzt werden können. Aus Sicht der Möglichkeiten, die KI bietet, wird deren Potenzial jedoch nur gering ausgeschöpft.

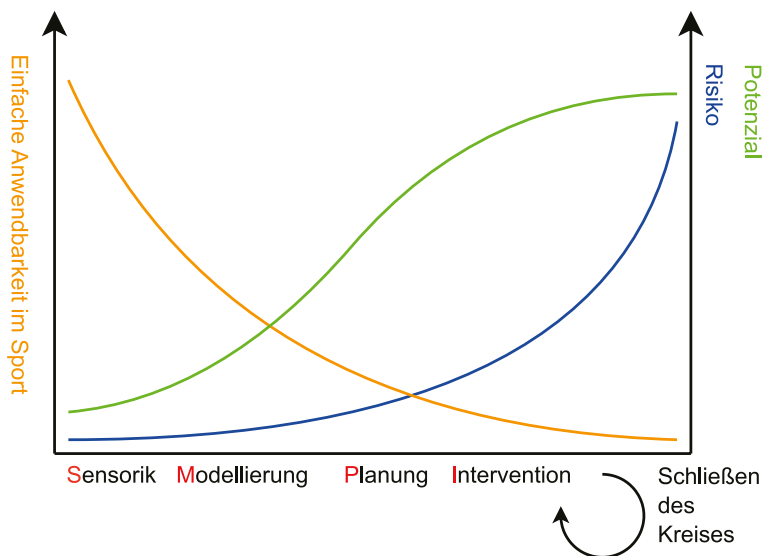


Abb. 14: Verhältnis von Risiko, Potenzial und Anwendbarkeit der KI im Spitzensport im Hinblick auf den Prozess von der Sensorik über die Modellierung und Planung bis zur Intervention und damit dem Schließen des KI-Kreislaufes

Im zweiten Teilschritt gilt es prädiktive Modelle der über die Sensorik wahrgenommenen Umgebung zu erstellen und diese im dritten Teilschritt zur Planung und Optimierung zu nutzen. Während das Potenzial mit der Umsetzung der Teilschritte Mo-

dellierung und Planung (Optimierung) bis zur Intervention stetig ansteigt (und direkt von aktuellen Entwicklungen in der KI profitieren kann), erhöht sich das Risiko insbesondere, wenn es um den letzten Schritt des KI-Kreises geht. D. h., gerade die Anwendung von KI im unmittelbaren Trainingsprozess (Intervention) und eine vollständig automatisierte, rückgekoppelte Prozessgestaltung, die durch KI unterstützt wird (iteratives Durchlaufen der KI-Schleife) hat großes Potenzial, ist jedoch mit einem hohen Risiko verbunden. Die Neuheit dieser Vorgehensweise bedingt unter anderem eine solide Evaluierung der Ergebnisse und durch die (Teil-) Automatisierung müssen beispielsweise im Falle der Trainingssteuerung mögliche Verletzungsrisiken beachtet werden. Dies bedeutet, dass eine vollständige KI im Spitzensport zwar das höchste Potenzial besitzt, aber der durch das gleichzeitig erhöhte Risiko bedingte verlängerte Zeithorizont bedacht werden muss. Aktuell bietet der Einsatz von KI in den ersten drei Teilschritten Sensorik, prädiktive Modellierung, Planung/Optimierung das vermutlich günstigste Risiko-Potenzial-Verhältnis.

# Literaturverzeichnis





- Adadi, A., & Berrada, M. (2018). Peeking inside the black-box: A survey on Explainable Artificial Intelligence (XAI). *IEEE Access*, 6, 52138-52160.
- Adhani, N. I., & Rambli, D. R. A. (2012). A survey of mobile augmented reality applications. In 1st International conference on future trends in computing and communication technologies (pp. 89-96).
- Alam, F., Mehmood, R., Katib, I., Albogami, N. N., & Albeshri, A. (2017). Data fusion and IoT for smart ubiquitous environments: A survey. *IEEE Access*, 5, 9533-9554.
- Alemdar, H., & Ersoy, C. (2010). Wireless sensor networks for healthcare: A survey. *Computer networks*, 54(15), 2688-2710.
- Anderson, F., Grossman, T., Matejka, J., & Fitzmaurice, G. (2013, October). YouMove: enhancing movement training with an augmented reality mirror. In *Proceedings of the 26th annual ACM symposium on User interface software and technology* (pp. 311-320).
- Ariki, Y., Shigemori, T., Kaneko, T., Ogata, J., & Fujimoto, M. (2003). Live speech recognition in sports games by adaptation of acoustic model and language model. In *Eighth European Conference on Speech Communication and Technology*.
- Arora, S., Du, S. S., Li, Z., Salakhutdinov, R., Wang, R., & Yu, D. (2019). Harnessing the power of infinitely wide deep nets on small-data tasks. *arXiv preprint arXiv:1910.01663*.
- Arts F. J. & Kuipers, H. (1994). The relation between power output, oxygen uptake and heart rate in male athletes. *International Journal of Sports Medicine* (pp. 228-231).
- Asteroth, A., Ludwig, M., Bach, K. (2020). Probabilistic Performance Profiling: A Model of the Power Duration Relation in Endurance Sports. *Proceedings of the 12th International Symposium on Computer Science in Sport* (pp. 123-131).
- Baillie, M., & Jose, J. M. (2003, July). Audio-based event detection for sports video. In *International Conference on Image and Video Retrieval* (pp. 300-309). Springer, Berlin, Heidelberg.
- Barbot, A., Decanini, D., & Hwang, G. (2016). On-chip microfluidic multimodal swimmer toward 3D navigation. *Scientific reports*, 6, 19041.

- Bass, C., da Silva, M., Sudre, C., Tudosiu, P. D., Smith, S., & Robinson, E. (2020). ICAM: Interpretable Classification via Disentangled Representations and Feature Attribution Mapping. arXiv preprint arXiv:2006.08287.
- Bergmann, S., Feldkamp, N., Conrad, F., & Strassburger, S. (2020, June). A Method for Robustness Optimization Using Generative Adversarial Networks. In Proceedings of the 2020 ACM SIGSIM Conference on Principles of Advanced Discrete Simulation (pp. 1-10).
- Bertsimas, D., Gupta, V., & Kallus, N. (2018). Data-driven robust optimization. *Mathematical Programming*, 167(2), 235-292.
- Besbes, B., Collette, S. N., Tamaazousti, M., Bourgeois, S., & Gay-Bellile, V. (2012, November). An interactive augmented reality system: a prototype for industrial maintenance training applications. In 2012 IEEE international symposium on mixed and augmented reality (ISMAR) (pp. 269-270). IEEE.
- Bourdon, P. C., Cardinale, M., Murray, A., Gatin, P. B., Kellmann, M., Varley, M. C., Gabbett, T. J., Coutts, A. J., Burgess, D. J., Gregson, W. & Cable, N. T. (2017). Monitoring Athlete Training Loads: Consensus Statement. *International Journal of Sports Physiology and Performance*, 12(Suppl 2), S2161-S2170.
- Chambers, G. S., Venkatesh, S., & West, G. A. (2004, August). Automatic labeling of sports video using umpire gesture recognition. In Joint IAPR International Workshops on Statistical Techniques in Pattern Recognition (SPR) and Structural and Syntactic Pattern Recognition (SSPR) (pp. 859-867). Springer, Berlin, Heidelberg.
- Chebotaev, Y., Handa, A., Makoviychuk, V., Macklin, M., Issac, J., Ratliff, N., & Fox, D. (2019, May). Closing the sim-to-real loop: Adapting simulation randomization with real world experience. In 2019 International Conference on Robotics and Automation (ICRA) (pp. 8973-8979). IEEE.
- Choi, J. H., & Lee, J. S. (2019). EmbraceNet: A robust deep learning architecture for multimodal classification. *Information Fusion*, 51, 259-270.
- Claudino, J. G., de Oliveira Capanema, D., de Souza, T. V., Serrão, J. C., Pereira, A. C. M., & Nassis, G. P. (2019). Current approaches

- to the use of artificial intelligence for injury risk assessment and performance prediction in team sports: a systematic review. *Sports medicine-open*, 5(1), 28.
- Colley, A., Väyrynen, J., & Häkkinen, J. (2015, September). Skiing in a blended virtuality: an in-the-wild experiment. In *Proceedings of the 19th International Academic Mindtrek Conference* (pp. 89-91).
- Cubuk, E. D., Sendek, A. D., & Reed, E. J. (2019). Screening billions of candidates for solid lithium-ion conductors: A transfer learning approach for small data. *The Journal of chemical physics*, 150(21), 214701.
- Cully, A., Clune, J., Tarapore, D., & Mouret, J. B. (2015). Robots that can adapt like animals. *Nature*, 521(7553), 503-507.
- Dadkhah, N., & Mettler, B. (2012). Survey of motion planning literature in the presence of uncertainty: Considerations for UAV guidance. *Journal of Intelligent & Robotic Systems*, 65(1-4), 233-246.
- Das, K., & Behera, R. N. (2017). A survey on machine learning: concept, algorithms and applications. *International Journal of Innovative Research in Computer and Communication Engineering*, 5(2), 1301-1309.
- Deb, K., & Jain, H. (2013). An evolutionary many-objective optimization algorithm using reference-point-based nondominated sorting approach, part I: solving problems with box constraints. *IEEE transactions on evolutionary computation*, 18(4), 577-601.
- Dunleavy, M., & Dede, C. (2014). Augmented reality teaching and learning. In *Handbook of research on educational communications and technology* (pp. 735-745). Springer, New York, NY.
- Emmerich, M., Yang, K., Deutz, A., Wang, H., & Fonseca, C. M. (2016). A multicriteria generalization of bayesian global optimization. In *Advances in Stochastic and Deterministic Global Optimization* (pp. 229-242). Springer, Cham.
- Faraway, J. J., & Augustin, N. H. (2018). When small data beats big data. *Statistics & Probability Letters*, 136, 142-145.

- Ferguson, A. R., Nielson, J. L., Cragin, M. H., Bandrowski, A. E., & Martone, M. E. (2014). Big data from small data: data-sharing in the 'long tail' of neuroscience. *Nature neuroscience*, 17(11), 1442-1447.
- Füller, M., Sundaram, A. M., Ludwig, M., Asteroth, A., & Prassler, E. (2015, May). Modeling and predicting the human heart rate during running exercise. In *International Conference on Information and Communication Technologies for Ageing Well and e-Health* (pp. 106-125). Springer, Cham.
- Gabrel, V., Murat, C., & Thiele, A. (2014). Recent advances in robust optimization: An overview. *European journal of operational research*, 235(3), 471-483.
- Gaier, A., Asteroth, A., & Mouret, J. B. (2017a). Aerodynamic design exploration through surrogate-assisted illumination. In *18th AIAA/ISSMO Multidisciplinary Analysis and Optimization Conference* (p. 3330).
- Gaier, A., Asteroth, A., & Mouret, J. B. (2017b, July). Data-efficient exploration, optimization, and modeling of diverse designs through surrogate-assisted illumination. In *Proceedings of the Genetic and Evolutionary Computation Conference* (pp. 99-106).
- Ghavamzadeh, M., Mannor, S., Pineau, J., & Tamar, A. (2016). Bayesian reinforcement learning: A survey. *arXiv preprint arXiv:1609.04436*.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT press.
- Gradl, S., Eskofier, B. M., Eskofier, D., Mutschler, C., & Otto, S. (2016, September). Virtual and augmented reality in sports: an overview and acceptance study. In *Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing: Adjunct* (pp. 885-888).
- Grambow, C. A., Li, Y. P., & Green, W. H. (2019). Accurate thermochemistry with small data sets: A bond additivity correction and transfer learning approach. *The Journal of Physical Chemistry A*, 123(27), 5826-5835.
- Hafner, D., Lillicrap, T., Fischer, I., Villegas, R., Ha, D., Lee, H., & Davidson, J. (2019, May). Learning latent dynamics for plan-

- ning from pixels. In International Conference on Machine Learning (pp. 2555-2565).
- Hagg, A., Hegger, F., & Plöger, P. G. (2016, June). On recognizing transparent objects in domestic environments using fusion of multiple sensor modalities. In Robot World Cup (pp. 3-15). Springer, Cham.
- Hagg, A., Asteroth, A., & Bäck, T. (2018, September). Prototype discovery using quality-diversity. In International Conference on Parallel Problem Solving from Nature (pp. 500-511). Springer, Cham.
- Hagg, A., Asteroth, A., & Bäck, T. (2019, July). Modeling user selection in quality diversity. In Proceedings of the Genetic and Evolutionary Computation Conference (pp. 116-124).
- Hagg, A., Asteroth, A., & Bäck, T. (2020). A Deep Dive Into Exploring the Preference Hypervolume. In International Conference on Computational Creativity 2020 (pp. 394-397).
- Hansen, N., Ostermeier, A. (2001). Completely derandomized self-adaptation in evolution strategies. *Evolutionary computation* 9.2 (pp. 159-195).
- He, X., Zhao, K., & Chu, X. (2021). AutoML: A Survey of the State-of-the-Art. *Knowledge-Based Systems*, 212, 106622.
- Hekler, E. B., Klasnja, P., Chevance, G., Golaszewski, N. M., Lewis, D., & Sim, I. (2019). Why we need a small data paradigm. *BMC medicine*, 17(1), 1-9.
- Hestness, J., Narang, S., Ardalani, N., Diamos, G., Jun, H., Kianinejad, H., ... & Zhou, Y. (2017). Deep Learning Scaling is Predictable, Empirically. arXiv preprint arXiv:1712.00409.
- Holzinger, A., Langs, G., Denk, H., Zatloukal, K., & Müller, H. (2019). Causability and explainability of artificial intelligence in medicine. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 9(4), e1312.
- Hsieh, H. Y., Chen, C. Y., Wang, Y. S., & Chuang, J. H. (2019, October). BasketballGAN: Generating basketball play simulation through sketching. In Proceedings of the 27th ACM International Conference on Multimedia (pp. 720-728).

- Jin, Y. (2011). Surrogate-assisted evolutionary computation: Recent advances and future challenges. *Swarm and Evolutionary Computation*, 1(2), 61-70.
- Jin, D., Xu, Z., Tang, Y., Harrison, A. P., & Mollura, D. J. (2018, September). CT-realistic lung nodule simulation from 3D conditional generative adversarial networks for robust lung segmentation. In *International Conference on Medical Image Computing and Computer-Assisted Intervention* (pp. 732-740). Springer, Cham.
- Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and electronics in agriculture*, 147, 70-90.
- Kim, T., Cha, M., Kim, H., Lee, J. K., & Kim, J. (2017). Learning to discover cross-domain relations with generative adversarial networks. arXiv preprint arXiv:1703.05192.
- Kitchin, R., & Lauriault, T. P. (2015). Small data in the era of big data. *GeoJournal*, 80(4), 463-475.
- Li, B., & Sezan, M. I. (2001, December). Event detection and summarization in sports video. In *Proceedings IEEE Workshop on Content-Based Access of Image and Video Libraries (CBA-IVL 2001)* (pp. 132-138). IEEE.
- Li, B., Li, J., Tang, K., & Yao, X. (2015). Many-objective evolutionary algorithms: A survey. *ACM Computing Surveys (CSUR)*, 48(1), 1-35.
- Li, Y. (2018). Deep reinforcement learning. arXiv preprint arXiv:1810.06339.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., ... & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical image analysis*, 42, 60-88.
- Liu, H., Ong, Y. S., Shen, X., & Cai, J. (2020). When Gaussian process meets big data: A review of scalable GPs. *IEEE Transactions on Neural Networks and Learning Systems*.
- Liu, J., Shahroudy, A., Perez, M. L., Wang, G., Duan, L. Y., & Chichung, A. K. (2019). Ntu rgb+ d 120: A large-scale benchmark for 3d human activity understanding. *IEEE transactions on pattern analysis and machine intelligence*.

- London, A. J. (2019). Artificial intelligence and black box medical decisions: accuracy versus explainability. *Hastings Center Report*, 49(1), 15-21.
- Lu, J., Behbood, V., Hao, P., Zuo, H., Xue, S., & Zhang, G. (2015). Transfer learning using computational intelligence: A survey. *Knowledge-Based Systems*, 80, 14-23.
- Ludwig, M., Sundaram, A. M., Füller, M., Asteroth, A., & Prassler, E. (2015, May). On Modeling the Cardiovascular System and Predicting the Human Heart Rate under Strain. In *ICT4AgeingWell* (pp. 106-117).
- Ludwig, M., & Asteroth, A. (2016a, September). Predicting performance from outdoor cycling training with the fitness-fatigue model. In *Proceedings dvs-workshop modelling in endurance sports*, University of Konstanz (pp. 3-6).
- Ludwig, M., Grohgan, H. G., & Asteroth, A. (2016b). A Convolution Model for Prediction of Physiological Responses to Physical Exercises. In *Sport Science Research and Technology Support* (pp. 18-35). Springer, Cham.
- Ludwig, M., & Asteroth, A. (2017). Preload for a More Reasonable Performance Prediction with the Fitness Fatigue Model.
- Ludwig, M., Hoffmann, K., Endler, S., Asteroth, A., & Wiemeyer, J. (2018). Measurement, prediction, and control of individual heart rate responses to exercise – Basics and options for wearable devices. *Frontiers in physiology*, 9, 778.
- Ludwig, M., Asteroth, M., Grohgan, H. (2019a). A Convolution Model for Prediction of Physiological Responses to Physical Exercises. *Sport Science Research and Technology Support* (pp.18-35).
- Ludwig, M., Asteroth, A., Rasche, C. & Pfeiffer, M. (2019b). Including the Past: Performance Modelling Using a Preload Concept by Means of the Fitness-Fatigue Model. *International Journal of Computer Science in Sport*, 18(1), 115–134.
- Lun, R., & Zhao, W. (2015). A survey of applications and human motion recognition with microsoft kinect. *International Journal of Pattern Recognition and Artificial Intelligence*, 29(05), 1555008.

- Lundberg, S. M., & Lee, S. I. (2017). A unified approach to interpreting model predictions. In *Advances in neural information processing systems* (pp. 4765-4774).
- Maaten, L. V. D., & Hinton, G. (2008). Visualizing data using t-SNE. *Journal of machine learning research*, 9(Nov), 2579-2605.
- Martin-Diaz, I., Morinigo-Sotelo, D., Duque-Perez, O., & Romero-Troncoso, R. D. J. (2016). Early fault detection in induction motors using AdaBoost with imbalanced small data and optimized sampling. *IEEE Transactions on Industry Applications*, 53(3), 3066-3075.
- Mencarini, E., Rapp, A., Tirabeni, L., & Zancanaro, M. (2019). Designing wearable systems for sports: A review of trends and opportunities in human-computer interaction. *IEEE Transactions on Human-Machine Systems*, 49(4), 314-325.
- Meyer, T., Ferrauti, A., Kellmann, M. & Pfeiffer, M. (Hg.). (2020). *Regenerationsmanagement im Spitzensport (Teil 2): REGman – Ergebnisse und Handlungsempfehlungen*. Sportverlag Strauß.
- Mittal, S., & Vaishay, S. (2019). A survey of techniques for optimizing deep learning on GPUs. *Journal of Systems Architecture*, 99, 101635.
- Natarajan, P., Atrey, P. K., & Kankanhalli, M. (2015). Multi-camera coordination and control in surveillance systems: A survey. *ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)*, 11(4), 1-30.
- Nishida, N., & Nakayama, H. (2015, November). Multimodal gesture recognition using multi-stream recurrent neural network. In *Image and Video Technology* (pp. 682-694). Springer, Cham.
- Olson, M., Wyner, A., & Berk, R. (2018). Modern neural networks generalize on small data sets. In *Advances in Neural Information Processing Systems* (pp. 3619-3628).
- Parent, M., Tiwari, A., Albuquerque, I., Gagnon, J. F., Lafond, D., Tremblay, S., & Falk, T. H. (2019, October). A Multimodal Approach to Improve the Robustness of Physiological Stress Prediction During Physical Activity. In *2019 IEEE Interna-*



- tional Conference on Systems, Man and Cybernetics (SMC) (pp. 4131-4136). IEEE.
- Pan, W. (2016). A survey of transfer learning for collaborative recommendation with auxiliary data. *Neurocomputing*, 177, 447-453.
- Parvat, A., Chavan, J., Kadam, S., Dev, S., & Pathak, V. (2017, January). A survey of deep-learning frameworks. In 2017 International Conference on Inventive Systems and Control (ICISC) (pp. 1-7). IEEE.
- Perl, J. (2012). Load Optimization in Endurance Sports by Means of Antagonistic Dynamical Models. *IFAC Proceedings Volumes*, 45(2), 810-813.
- Perl, J. & Pfeiffer, M. (2011). PerPot DoMo: Antagonistic Meta-Model Processing two Concurrent Load Flows. *International Journal of Computer Science in Sport*, 10(2).
- Pfeiffer, M., Zhang, H., und Hohmann, A. (2010). A markov chain model of elite table tennis competition. *International journal of sports science & coaching*, 5(2), Seiten: 205-222.
- Pfeiffer, M. (2005). Leistungsdiagnostik im Nachwuchstraining der Sportspiele : Ent-wicklung eines modelltheoretischen Ansatzes im Handball (S. 262 S.). Sport und Buch Strauß.
- Pouyanfar, S., Sadiq, S., Yan, Y., Tian, H., Tao, Y., Reyes, M. P. & Iyengar, S. S. (2018). A survey on deep learning: Algorithms, techniques, and applications. *ACM Computing Surveys (CSUR)*, 51(5), 1-36.
- Preece, A. (2018). Asking 'Why' in AI: Explainability of intelligent systems – perspectives and challenges. *Intelligent Systems in Accounting, Finance and Management*, 25(2), 63-72.
- Rasche, C. & Pfeiffer, M. (2019). Training. In A. Baca & J. Perl (Hg.), *Routledge research in sport and exercise science. Modelling and Simulation in Sport and Exercise* (1. Aufl., S. 187-207). Routledge. Part IV: Physiological Conditions of Being Successful.
- Rasmussen, C. E. (2003, February). Gaussian processes in machine learning. In *Summer School on Machine Learning* (pp. 63-71). Springer, Berlin, Heidelberg.

- Rasmussen, C. E., Williams, C. K. (2008). Gaussian processes for machine learning. Cambridge, Mass: MIT Press.
- Ribeiro, M. T., Singh, S., & Guestrin, C. (2016, August). „Why should I trust you?“ Explaining the predictions of any classifier. In Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining (pp. 1135-1144).
- Rosenfeld, A., & Richardson, A. (2019). Explainability in human-agent systems. *Autonomous Agents and Multi-Agent Systems*, 33(6), 673-705.
- Russel, S. J. & Norvig, P. (2020). *Artificial Intelligence: A Modern Approach* (4. Aufl.). Pearson.
- Sano, Y., Sato, K., Shiraishi, R., & Otsuki, M. (2016, November). Sports support system: Augmented ball game for filling gap between player skill levels. In Proceedings of the 2016 ACM International Conference on Interactive Surfaces and Spaces (pp. 361-366).
- Schaefer, D., Asteroth, A., & Ludwig, M. (2015, September). Training plan evolution based on training models. In 2015 International Symposium on INnovations in Intelligent SysTems and Applications (INISTA) (pp. 1-8). IEEE.
- Schlegl, T., Seeböck, P., Waldstein, S. M., Schmidt-Erfurth, U., & Langs, G. (2017, June). Unsupervised anomaly detection with generative adversarial networks to guide marker discovery. In International conference on information processing in medical imaging (pp. 146-157). Springer, Cham.
- Shahid, N., Naqvi, I. H., & Qaisar, S. B. (2015). Characteristics and classification of outlier detection techniques for wireless sensor networks in harsh environments: a survey. *Artificial Intelligence Review*, 43(2), 193-228.
- Shahroudy, A., Liu, J., Ng, T. T., & Wang, G. (2016). Ntu rgb+ d: A large scale dataset for 3d human activity analysis. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 1010-1019).
- Shahriari, B., Swersky, K., Wang, Z., Adams, R. P., & De Freitas, N. (2015). Taking the human out of the loop: A review of Bayesian optimization. *Proceedings of the IEEE*, 104(1), 148-175.

- Shaikhina, T., Lowe, D., Daga, S., Briggs, D., Higgins, R., & Khovanova, N. (2015). Machine learning for predictive modelling based on small data in biomedical engineering. *IFAC-PapersOnLine*, 48(20), 469-474.
- Sokol, K., & Flach, P. (2020, January). Explainability fact sheets: a framework for systematic assessment of explainable approaches. In *Proceedings of the 2020 Conference on Fairness, Accountability, and Transparency* (pp. 56-67).
- Stephens Hemingway, B. H., Greig, L., Jovanovic, M., Ogorek, B. & Swinton, P. (2020). Traditional and contemporary approaches to mathematical fitness-fatigue models in exercise science: A practical guide with resources. Part I. Vorab-Onlinepublikation. <https://doi.org/10.31236/osf.io/ap75j>
- Swinton, P., Stephens Hemingway, B. H., Rasche, C., Pfeiffer, M. & Ogorek, B. (2021). Traditional and contemporary approaches to mathematical fitness-fatigue models in exercise science: A practical guide with resources. Part II. Vorab-Onlinepublikation. <https://doi.org/10.31236/osf.io/5qgc2>
- Tjoa, E., & Guan, C. (2019). A survey on explainable artificial intelligence (XAI): towards medical XAI. *arXiv preprint arXiv:1907.07374*.
- Tomašev, N., & Radovanović, M. (2016). Clustering evaluation in high-dimensional data. In *Unsupervised Learning Algorithms* (pp. 71-107). Springer, Cham.
- Tsetserukou, D., Sato, K., & Tachi, S. (2010, April). ExoInterfaces: novel exoskeleton haptic interfaces for virtual reality, augmented sport and rehabilitation. In *Proceedings of the 1st Augmented Human International Conference* (pp. 1-6).
- Urquhart, N., & Hart, E. (2018, September). Optimisation and illumination of a real-world workforce scheduling and routing application (WSRP) via Map-Elites. In *International Conference on Parallel Problem Solving from Nature* (pp. 488-499). Springer, Cham.
- Vanhatalo, J., Riihimäki, J., Hartikainen, J., Jylänki, P., Tolvanen, V., & Vehtari, A. (2013). GPstuff: Bayesian modeling with Gaussian processes. *Journal of Machine Learning Research*, 14(Apr), 1175-1179.

- van Stein, B., Wang, H., Kowalczyk, W., Bäck, T., & Emmerich, M. (2015, October). Optimally weighted cluster kriging for big data regression. In *International Symposium on Intelligent Data Analysis* (pp. 310-321). Springer, Cham.
- Vásquez-Correa, J. C., Arias-Vergara, T., Orozco-Arroyave, J. R., Eskofier, B., Klucken, J., & Nöth, E. (2018). Multimodal assessment of Parkinson's disease: a deep learning approach. *IEEE journal of biomedical and health informatics*, 23(4), 1618-1630.
- Vinyals, M., Rodriguez-Aguilar, J. A., & Cerquides, J. (2011). A survey on sensor networks from a multiagent perspective. *The Computer Journal*, 54(3), 455-470.
- Wang, P., Li, W., Ogunbona, P., Wan, J., & Escalera, S. (2018). RGB-D-based human motion recognition with deep learning: A survey. *Computer Vision and Image Understanding*, 171, 118-139.
- Wang, T., Wang, C., Zhou, X., & Chen, H. (2018). A survey of FPGA based deep learning accelerators: Challenges and opportunities. *arXiv preprint arXiv:1901.04988*, 1-10.
- Wang, J., Chen, Y., Hao, S., Peng, X., & Hu, L. (2019). Deep learning for sensor-based activity recognition: A survey. *Pattern Recognition Letters*, 119, 3-11.
- Weinland, D., Ronfard, R., & Boyer, E. (2011). A survey of vision-based methods for action representation, segmentation and recognition. *Computer vision and image understanding*, 115(2), 224-241.
- Winter, C., Pfeiffer, M. (2019). Quantitative Spielanalyse : den Überblick bei zunehmender Heterogenität der Ansätze behalten. *German journal of exercise and sport research*, 50(1), Seiten: 51-59. <http://dx.doi.org/10.1007/s12662-019-00623-z>
- Xie, Z., Clary, P., Dao, J., Morais, P., Hurst, J., & Panne, M. (2020, May). Learning locomotion skills for cassie: Iterative design and sim-to-real. In *Conference on Robot Learning* (pp. 317-329).
- Xu, M., Duan, L. Y., Xu, C. S., & Tian, Q. (2003, July). A fusion scheme of visual and auditory modalities for event detection in sports video. In *2003 International Conference on Multimedia and Expo. ICME'03. Proceedings (Cat. No. 03TH8698)* (Vol. 1, pp. I-333). IEEE.

- Xu, G., Ma, Y. F., Zhang, H. J., & Yang, S. (2003, September). A HMM based semantic analysis framework for sports game event detection. In Proceedings 2003 International Conference on Image Processing (Cat. No. 03CH37429) (Vol. 1, pp. I-25). IEEE.
- Xu, M., Duan, L. Y., Chia, L. T., & Xu, C. S. (2004, October). Audio keyword generation for sports video analysis. In Proceedings of the 12th annual ACM international conference on Multimedia (pp. 758-759).
- Yang, Q., Liu, Y., Chen, T., & Tong, Y. (2019). Federated machine learning: Concept and applications. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 10(2), 1-19.
- Zhang, H., Xu, T., Li, H., Zhang, S., Wang, X., Huang, X., & Metaxas, D. N. (2017). Stackgan: Text to photo-realistic image synthesis with stacked generative adversarial networks. In Proceedings of the IEEE international conference on computer vision (pp. 5907-5915).
- Zhu, G., Xu, C., Huang, Q., Gao, W., & Xing, L. (2006, October). Player action recognition in broadcast tennis video with applications to semantic analysis of sports game. In Proceedings of the 14th ACM international conference on Multimedia (pp. 431-440).

## Schriftenreihe des Bundesinstituts für Sportwissenschaften im SPORTVERLAG Strauß

### Band 2009,01

Stahl, Silvester  
**Selbstorganisation von Migranten im deutschen Vereinssport.** Ein Forschungsbericht zu Formen, Ursachen und Wirkungen. 148 Seiten, 21 cm, kt.  
978-3-86884-510-5 € 16,80

### Band 2009,02

Kämpfe, Astrid  
**Homo Sportivus Oeconomicus.** Intrinsische und extrinsische Motivation im Verlauf von Spitzensportkarrieren. 403 Seiten, 21 cm, kt.  
978-3-86884-511-2 € 28,80

### Band 2010,01

Schmieg, Peter / Voriskova, Sarka / Marquardt, Gesine / Glasow, Nadine  
**Bauliche Voraussetzungen für den paralympischen Sport.** Forschungsprojekt im Auftrag des Bundesinstituts für Sportwissenschaft Bonn. 304 Seiten, 21 cm, kt.  
978-3-86884-512-9 € 24,80

### Band 2010,02

Faude, Oliver / Wegmann, Melissa / Krieg, Anne / Meyer, Tim  
**Kälteapplikationen im Spitzensport.** Eine Bestandsaufnahme der wissenschaftlichen Evidenz. 144 Seiten, 21 cm, kt.  
978-3-86884-513-6 € 15,80

### Band 2010,03

Fahrig, Stephan  
**Zur Interaktionsproblematik im Riemenzweier der Sportart Rudern.** 174 Seiten, 21 cm, kt.  
978-3-86884-514-3 € 17,80

### Band 2011,01

Schlesiger, Günter  
**Sportplätze.** Sportfreianlagen: Planung – Bau – Ausstattung – Pflege. 324 Seiten, 29,7 cm, kt.  
978-3-86884-515-0 € 58,00

### Band 2011,02

Wirth, Klaus  
**Exzentrisches Krafttraining.** Auswirkungen auf unterschiedliche Maximal- und Schnellkraftparameter. 714 Seiten, 21 cm, kt.  
978-3-86884-516-7 € 42,80

### Band 2011,03

Braun, Sebastian  
**Ehrenamtliches und freiwilliges Engagement im Sport.** Sportbezogene Sonderauswertung der Freiwilligen-surveys von 1999, 2004 und 2009. 80 Seiten, 21 cm, kt.  
978-3-86884-517-4 € 12,80

### Band 2011,04

Ott, Peter  
**Planung und Bau von Tanzsportanlagen.** Eine Orientierungshilfe des Bundesinstituts für Sportwissenschaft. 52 Seiten, 29,7 cm, kt.  
978-3-86884-518-1 € 21,80

**Band 2011,05**

Wyns, Bernhard

**Betreibermodelle öffentlicher Bäder.**

Wirkung von Betreibermodellen auf die Betriebsführung, Personalwirtschaft und Sportnachfrage. 490 Seiten, 21 cm, kt.

978-3-86884-519-8 € 58,00

**Band 2011,06**

Krause, Daniel

**Zur Darstellungsperspektive von Bildschirminstruktion und -feedback beim visuomotorischen Imitationslernen.**

Laborexperimentelle Untersuchungen zu den Effekten verschiedener Faktoren im Kontext der Darstellungsperspektivenauswahl: Bild-Bewegungsebenen-Disparität, Modell-Betrachter-Disparität, Perspektivenanzahl und Selbstkontrolle. 386 Seiten, 21 cm, kt.

978-3-86884-520-4 € 29,80

**Band 2012,01**

Wirth, Klaus / Schlumberger, Andreas / Zawieja, Martin / Hartmann, Hagen  
**Krafttraining im Leistungssport.** Theoretische und praktische Grundlagen für Trainer und Athleten. 2., korr. Aufl. 2013. 148 Seiten, 30 cm, kt.

978-3-86884-521-1 € 29,80

**Band 2012,02**

Kalbe, Ute / Krüger, Oliver / Wachtendorf, Volker / Berger, Wolfgang  
**Umweltverträglichkeit von Kunststoff- und Kunststoffrasenbelägen auf Sportfreianlagen.** Erfassung von potentiellen Schadstoffen bei Sportböden auf Kunststoffbasis (Kunststoff- und Kunststoffrasenbeläge) auf Sportfreianlagen, unter Berücksichtigung von Alterungs- und Verschleißprozessen. 302 Seiten, 21 cm, kt.

978-3-86884-522-8 € 34,80

**Band 2013,01**

Daumann, Frank / Römmelt, Benedikt

**Qualitätsmanagement im Bundessportfachverband.** Qualitätsrelevante Stakeholder in Bundessportfachverbänden – Eine qualitative Studie als Basis für die Implementierung eines Qualitätsmanagementsystems. 536 Seiten, 21 cm, kt.

978-3-86884-523-5 € 36,00

**Band 2013,02**

Stadtman, Tobias

**Optimierung von Talentselektion und Nachwuchsförderung im Deutschen Basketball Bund aus trainingswissenschaftlicher Sicht.** 428 Seiten, 21 cm, kt.

978-3-86884-524-2 € 39,80

**Band 2013,03**

Braun, Sebastian

**Freiwilliges Engagement von Jugendlichen im Sport.** Eine empirische Untersuchung auf Basis der Freiwilligensurveys von 1999 bis 2009. 108 Seiten, 21 cm, kt.

978-3-86884-525-9 € 12,80

**Band 2014,01**

Zastrow, Hilke / Schlapkohl, Nele / Raab, Markus

**DeMaTra – Ein Messplatztraining für taktische Kompetenzen im Handball.** 164 Seiten, 21 cm, kt.

978-3-86884-526-6 € 24,80

**Band 2014,02**

Radtke, Sabine / Doll-Tepper, Gudrun  
**Nachwuchsgewinnung und -förderung im paralympischen Sport.** Ein internationaler Systemvergleich unter Berücksichtigung der Athleten-, Trainer- und Funktionsperspektive. 392 Seiten, 21 cm, kt.

978-3-86884-527-3 € 38,80

**Band 2014,03**

Kleinert, Jens

**Toolbox Beziehungsarbeit: Zur Beziehungsqualität in der sportpsychologischen Betreuung.** Beitrag Qualitätssicherung in der Sportpsychologie. 68 Seiten, 30 cm, kt.

978-3-86884-528-0 € 21,80

**Band 2014,04**

Brand, Ralf u. a.

**Leitfaden zur Qualitätssicherung für die sportpsychologische Betreuung im Leistungssport.** Beitrag Qualitätssicherung in der Sportpsychologie. 96 Seiten, 30 cm, kt.

978-3-86884-529-7 € 28,80

**Band 2015,01**

Eßig, Natalie / Lindner, Sara / Magdolen, Simone / Siegmund, Loni

**Leitfaden Nachhaltiger Sportstättenbau – Kriterien für den Neubau nachhaltiger Sporthallen.** 424 Seiten, 21 cm, kt.

978-3-86884-530-3 € 49,80

**Band 2015,02**

Gerland, Bernd Paul

**Der Yips – eine erlernte Störung motorischer Leistungsvollzüge?** Phänomenanalyse und Interventionsmöglichkeiten am Beispiel des Putt-Yips im Golf. 210 Seiten, 30 cm, kt.

978-3-86884-531-0 € 42,80

**Band 2016,01**

Braun, Sebastian

**Ehrenamtliches und freiwilliges Engagement von Älteren im Sport.** Sportbezogene Sonderauswertung der Freiwilligensurveys von 1999, 2004 und 2009. 72 Seiten, 30 cm, kt.

978-3-86884-532-7 **vergriffen****Band 2016,02**

Linz, Lothar / Ohlert, Jeannine

**Sportpsychologische Verbandskonzeption des Deutschen Handballbundes 2016-2020.** 64 Seiten, 30 cm, kt.

978-3-86884-533-4 **vergriffen****Band 2016,03**

Klietsch, Heiko

**Mediengerechte Sportanlagen.**

Mediale Raum-/Flächen- und Ausstattungsprogramme in Stadien und Arenen aus dem Bereich des Fernsehens, der Mess- und Kommunikationstechnik. 472 Seiten, 21 cm, kt.

978-3-86884-534-1 € 56,80

**Band 2016,04**

Killing, Wolfgang / Böttcher, Jörg / Keil, Jan-Gerrit

**Sportwissenschaftliche Aspekte des Hochsprungs.** 2. korrigierte Aufl. 2017. 300 Seiten, 30 cm, kt.

978-3-86884-535-8 € 49,00

**Band 2016,05**

Kalbe, Ute / Susset, Bernd / Bandow, Nicole

**Umweltverträglichkeit von Kunststoffbelägen auf Sportfreianlagen.**

Modellierung der Stofffreisetzung aus Sportböden auf Kunststoffbasis zur Bewertung der Boden- und Grundwasserungsverträglichkeit. 428 Seiten, 21 cm, kt.

978-3-86884-536-5 € 49,80

**Band 2016,06**

Hohmann, Andreas / Singh, Ajit / Voigt, Lenard

**Konzepte erfolgreichen Nachwuchstrainings (KerN).** Abschlussbericht zum Forschungsprojekt „Langfristiger Leistungsaufbau im Nachwuchsleistungssport“. 336 Seiten, 30 cm, kt.

978-3-86884-537-2 € 49,80



**Band 2016,07**

Kellmann, Michael / Kölling, Sarah / Hitzschke, Brit  
**Das Akutmaß und die Kurzska-  
 la zur Erfassung von Erholung und  
 Beanspruchung im Sport.** Manual. 124  
 Seiten, 30 cm, kt.  
 978-3-86884-538-9 € 33,00

**Band 2017,01**

Hohmann, Andreas / Pietzonka, Micha  
**Techniktraining zur Entwicklung der  
 Spielfähigkeit im Fußball, Handball  
 und Basketball.** 568 Seiten, 30 cm, kt.  
 978-3-86884-539-6 € 59,00

**Band 2017,02**

Breuer, Christoph / Wicker, Pamela /  
 Orłowski, Johannes  
**Bundes- und mischfinanzierte Trainer  
 im Sport – Standortbedingungen und  
 Migrationsanalyse.** 176 Seiten, 21 cm,  
 kt.  
 978-3-86884-540-2 € 19,80

**Band 2017,03**

Leistner, Philip / Koehler, Mark  
**Verbesserung der akustischen Eigen-  
 schaften von Sporthallenböden.** 116  
 Seiten, 21 cm, kt.  
 978-3-86884-541-9 € 19,80

**Band 2017,04**

Weber, Christoph  
**Theoretische und praktische Leis-  
 tungsdiagnostik im Goalball.** 204  
 Seiten, 30 cm, kt.  
 978-3-86884-542-6 € 39,80

**Band 2017,05**

Loffing, Florian / Neugebauer, Judith /  
 Hagemann, Jörg / Schorer, Jörg  
**Eye-racking im Spitzensport – Validi-  
 tät, Grenzen und Möglichkeiten.** 136  
 Seiten, 30 cm, kt.  
 978-3-86884-543-3 € 29,80

**Band 2019,01**

Daumann, Frank (Projektleitung) /  
 Heinze, Robin / Kümpe, Jeremias /  
 Barth, Michael / Diethold, Sascha-  
 Gregor  
**Quality Performance Measurement in  
 National Sport-Governing Bodies.** 396  
 Seiten, 21 cm, kt..  
 978-3-86884-544-0 € 39,80

**Band 2019,02**

Killing, Wolfgang  
**Evaluation sportwissenschaftlicher  
 Unterstützungsleistungen im Spit-  
 zensport am Beispiel der Leichtathle-  
 tik.** 242 Seiten, 30 cm, kt.  
 978-3-86884-545-7 € 49,80

**Band 2019,03**

Krüger, Michael / Nielsen, Stefan /  
 Becker, Christian / Rehmann, Lukas  
**Sportmedizin zwischen Sport, Wis-  
 senschaft und Politik – eine deutsche  
 Geschichte.** Ein Forschungsprojekt  
 zur Ge-  
 schichte der Sportmedizin. 404  
 Seiten, 30 cm, kt.  
 978-3-86884-546-4 € 64,80

## Publikationen ohne Band-Nummerierung

Beckmann, Jürgen / Wenhold, Franziska

### Handlungsorientierung im Sport.

Manual zur Handlungsorientierung im Sport (HOSP). 1. Aufl. 2009. 48 Seiten, 29,7 cm, kt.

978-3-86884-508-2 € 16,00

Behringer, Michael / Heede, Andreas vom / Mester, Joachim

### Krafttraining im Nachwuchsleistungssport unter besonderer Berücksichtigung von Diagnostik, Trainierbarkeit und Trainingsmethodik. Wissenschaftliche Expertise des BISp, Band II. 1.

Aufl. 2010. 194 Seiten, 21 cm, kt.

978-3-86884-487-0 € 17,80

Brand, Ralf / Ehrlenspiel, Felix / Graf, Karla

### Wettkampf-Angst-Inventar (WAI).

Manual zur comprehensiven Eingangsdiagnostik von Wettkampfangst, Wettkampffähigkeit und Angstbewältigungsmodus im Sport. 1. Aufl. 2009. 150 Seiten, 29,7 cm, kt.

978-3-86884-491-7 € 26,80

Brejcha-Richter, Stanislav / Hillenbach, Elke / Klein, Klaus / Kukowka, Dorothea

### 40 Jahre Bundesinstitut für Sportwissenschaft. Bilanz und Ausblick.

Dokumentation der Festveranstaltung. 1. Aufl. 2011. 64 Seiten, 21 cm, kt.

978-3-86884-455-9 € 12,00

Breuer, Christoph (Hrsg.)

### Sportentwicklungsbericht 2007/2008.

Analyse zur Situation der Sportvereine in Deutschland. 1. Aufl. 2009. 740 Seiten, 21 cm, kt.

978-3-86884-500-6 € 48,00

Breuer, Christoph (Hrsg.)

### Sportentwicklungsbericht 2009/2010.

Analyse zur Situation der Sportvereine in Deutschland. 1. Aufl. 2011. 596 Seiten, 21 cm, kt.

978-3-86884-456-6 € 38,80

Breuer, Christoph (Hrsg.)

### Sportentwicklungsbericht 2011/2012.

Analyse zur Situation der Sportvereine in Deutschland. 1. Aufl. 2013. 902 Seiten, 21 cm, kt.

978-3-86884-463-4 vergriffen

Breuer, Christoph (Hrsg.)

### Sportentwicklungsbericht 2013/2014.

Analyse zur Situation der Sportvereine in Deutschland. 1. Aufl. 2015. 864 Seiten, 21 cm, kt.

978-3-86884-581-5 € 48,80

Breuer, Christoph (Hrsg.)

### Sportentwicklungsbericht 2015/2016.

Bd. I. Analyse zur Situation der Sportvereine in Deutschland. 1. Aufl. 2017. 830 Seiten, zahlr. z. T. farb. Abb. und Tab., 21 cm, kt.

978-3-86884-595-2 € 48,00

Breuer, Christoph (Hrsg.)

### Sportentwicklungsbericht 2015/2016.

Bd. II. Weiterführende Strukturanalysen. 1. Aufl. 2017. 648 Seiten, zahlr. z. T. farb. Abb. und Tab., 21 cm, kt.

978-3-86884-596-9 € 48,00

Breuer, Christoph (Hrsg.)

### Sportverbände, Sportvereine und ausgewählte Sportarten.

Weiterführende Analysen der Sportentwicklungsberichte. 1. Aufl. 2013. 452 Seiten, 21 cm, kt.

978-3-86884-580-8 € 34,80

- Breuer, Christoph / Feiler, Svenja  
**Sportentwicklungsbericht 2011/2012.**  
 Analyse zur Situation der Sportvereine  
 in Deutschland. Kurzfassung. 1. Aufl.  
 2013. 54 Seiten, 21 cm, kt.  
 978-3-86884-464-1 **12,00**
- Breuer, Christoph / Feiler, Svenja  
**Sport Development Report**  
**2013/2014.** Analysis of the situation of  
 sports clubs in Germany. Abbreviated  
 Version. 1. Aufl. 2015. 42 Seiten, 21  
 cm, kt.  
 978-3-86884-583-9 **€ 14,00**
- Breuer, Christoph / Feiler, Svenja  
**Sportentwicklungsbericht 2013/2014.**  
 Analyse zur Situation der Sportvereine  
 in Deutschland. Kurzfassung. 1. Aufl.  
 2015. 46 Seiten, 21 cm, kt.  
 978-3-86884-582-2 **€ 12,00**
- Breuer, Christoph / Feiler, Svenja  
**Sport Development Report**  
**2015/2016.** Analysis of the situation of  
 sports clubs in Germany. Abbreviated  
 Version. 1. Aufl. 2017. 40 Seiten, 11 z. T.  
 farb. Abb. 18 Tab. 21 cm, kt.  
 978-3-86884-586-0 **€ 14,00**
- Breuer, Christoph / Feiler, Svenja  
**Sportentwicklungsbericht 2015/2016.**  
 Analyse zur Situation der Sportvereine  
 in Deutschland. Kurzfassung. 1. Aufl.  
 2017. 40 Seiten, 11 z. T. farb. Abb. 18  
 Tab. 21 cm, kt.  
 978-3-86884-585-3 **€ 12,00**
- Breuer, Christoph / Hallmann, Kirstin  
**Die gesellschaftliche Relevanz des**  
**Spitzensports in Deutschland.** 1. Aufl.  
 2012. 48 Seiten, 21 cm, kt.  
 978-3-86884-467-2 **€ 12,00**
- Breuer, Christoph / Hallmann, Kirstin /  
 Ilgner, Michael  
**Akzeptanz des Spitzensports in**  
**Deutschland – Zum Wandel der**  
**Wahrnehmung durch Bevölkerung**  
**und Athleten.** 1. Aufl. 2017. 52 Seiten,  
 7 farb. Abb. 21 Tab. 21 cm, kt.  
 978-3-86884-584-6 **vergriffen**
- Breuer, Christoph / Hallmann, Kirstin /  
 Ilgner, Michael  
**Erfolgsfaktoren der Athletenförde-**  
**rung in Deutschland.** 1. Aufl. 2015. 86  
 S. 17 Abb. 17 Tab. 21 cm.  
 978-3-86884-594-5 **€ 14,80**
- Breuer, Christoph / Wicker, Pamela  
**Zur Situation der Sportarten in**  
**Deutschland.** Eine Analyse der Sport-  
 vereine in Deutschland auf Basis der  
 Sportentwicklungsberichte. 1. Aufl.  
 2011. 384 Seiten, 21 cm, kt.  
 978-3-86884-460-3 **€ 28,40**
- Breuer, Christoph / Wicker, Pamela  
**Sportökonomische Analyse der Le-**  
**benssituation von Spitzensportlern in**  
**Deutschland.** 1. Aufl. 2010. 58 Seiten,  
 21 cm, kt.  
 978-3-86884-477-1 **€ 12,00**
- Bundesinstitut für Sportwissenschaft  
 (Hrsg.)  
**BISp-Handreichung zur Expertise**  
**Krafttraining im Nachwuchsleis-**  
**tungssport.** 1. Aufl. 2010. 46 Seiten,  
 21 cm, kt.  
 978-3-86884-488-7 **vergriffen**
- Elbe, Anne-Marie / Wenhold, Franzika/  
 Beckmann, Jürgen  
**Fragebogen zur Leistungsorientierung**  
**im Sport.** Sport Orientation Question-  
 naire (SOQ). 1. Aufl. 2009. 44 Seiten,  
 29,7 cm, kt.  
 978-3-86884-493-1 **€ 16,00**

Eskau, Andrea (Red.)

**Nachwuchsrekrutierung und Nachwuchsförderung im Leistungssport der Menschen mit Behinderungen.**

BISp-Arbeitstagung. Bonn, 14. / 15. Mai. 1. Aufl. 2009. 202 Seiten, 29,7 cm, kt.

978-3-86884-507-5 € 24,00

Eskau, Andrea (Red.)

**Regenerationsmanagement und Sporttechnologie im Leistungssport der Menschen mit Behinderungen. 1.**

Aufl. 2013. 92 Seiten, 21 cm, kt.

978-3-86884-590-7 € 18,00

Ferrauti, Alexander u. a.

**Basketball Talente.** Leitlinien und Empfehlungen auf dem Weg zur Spitze. 1. Aufl. 2015. 38 Seiten, 10,5 x 30 cm, kt.

978-3-86884-591-4 vergriffen

Gänsslen, Axel / Schmehl, Ingo

**Leichtes Schädel-Hirn-Trauma im Sport.** Handlungsempfehlungen. 1. Aufl. 2015. 44 Seiten, 21 cm, kt.

978-3-86884-593-8 € 9,80

Hahn, Andreas u. a. (Hrsg.)

**Biomechanische Leistungsdiagnostik im Schwimmen.** Erfahrungen im Leistungssport und Ableitungen für die Ausbildung von Studierenden. Beiträge zum dvs-Symposium Schwimmen 10.-12.09.2009 in Leipzig. 1. Aufl. 2010. 188 Seiten, 21 cm, kt.

978-3-86884-489-4 € 18,00

Hartmann, Ulrich u. a.

**Krafttraining im Nachwuchsleistungssport unter besonderer Berücksichtigung von Ontogenese, biologischen Mechanismen und Terminologie.** Wissenschaftliche Expertise des BISp, Band I. 1. Aufl. 2010. 312 Seiten, 21 cm, kt.

978-3-86884-486-3 € 23,80

Hillenbach, Elke (Red.)

**BISp-Jahrbuch.** Forschungsförderung 2011/12. 1. Aufl. 2012. 174 Seiten, 29,7 cm, kt.

978-3-86884-462-7 € 28,00

Hillenbach, Elke (Red.)

**BISp-Jahrbuch.** Forschungsförderung 2014/15. 1. Aufl. 2016. 262 Seiten, 29,7 cm, kt.

978-3-86884-632-4 € 28,00

Hillenbach, Elke (Red.)

**BISp-Jahrbuch.** Forschungsförderung 2015/16. 1. Aufl. 2016. 226 Seiten, 29,7 cm, kt.

978-3-86884-633-1 € 28,00

Hillenbach, Elke (Red.)

**BISp-Jahrbuch.** Forschungsförderung 2016/17. 1. Aufl. 2018. 368 Seiten, 29,7 cm, kt.

978-3-86884-634-8 € 48,00

Horn, Andrea / Neumann, Gabriele (Hrsg.)

**BISp-Ratgeber Projektförderung.**

Von der Idee zum erfolgreichen Projekt. Möglichkeiten und Wege der Projektförderung beim Bundesinstitut für Sportwissenschaft. 2. Aufl. 2009. 60 Seiten, 29,7 cm, kt.

978-3-86884-482-5 € 12,00

Kellmann, Michael / Weidig, Thorsten

**Pausenverhaltensfragebogen (PVF)-Manual.** 1. Aufl. 2010. 94 Seiten, 29,7 cm, kt.

978-3-86884-485-6 € 16,00

Killing, Wolfgang / Hommel, Helmar

**Bundestrainerforum „DLV-Kältekonferenz“** 06.-07.12.2008 in Mainz. 1. Aufl. 2009. 76 Seiten, 21 cm, kt.

978-3-86884-496-2 € 14,80

- Killing, Wolfgang / Hommel, Helmar  
**Bundestrainerforum „DLV-Kraftkonferenzen“** 15.–16.11.2008 in Potsdam. 1. Aufl. 2009. 172 Seiten, 21 cm, kt.  
 978-3-86884-495-5 **vergriffen**
- Klein, Klaus / Koch, Thomas / Palmen, Michael / Weinke, Irina (Red.)  
**BISp-Report 2009/10.** Bilanz und Perspektiven. 1. Aufl. 2010. 130 Seiten, 30 cm, kt.  
 978-3-86884-471-9 **€ 14,80**
- Klein, Klaus / Koch, Thomas / Palmen, Michael / Koch, Irina (Red.)  
**BISp-Report 2010/11.** Bilanz und Perspektiven. 1. Aufl. 2012. 126 Seiten, 30 cm, kt.  
 978-3-86884-468-9 **€ 14,80**
- Klein, Klaus / Palmen, Michael / Stell, Sabine / Streppelhoff, Robin (Red.)  
**BISp-Report 2012.** Bilanz und Perspektiven. 1. Aufl. 2013. 86 Seiten, 30 cm, kt.  
 978-3-86884-570-9 **€ 19,80**
- Klein, Klaus u. a. (Red.)  
**BISp-Report 2014/15.** Bilanz und Perspektiven. 1. Aufl. 2015. 102 Seiten, 30 cm, kt.  
 978-3-86884-572-3 **€ 19,80**
- Klein, Klaus u. a. (Red.)  
**BISp-Report 2015/16.** Bilanz und Perspektiven. 1. Aufl. 2016. 110 Seiten, 30 cm, kt.  
 978-3-86884-573-0 **€ 8,60**
- Klein, Klaus u. a. (Red.)  
**BISp-Report 2016/17.** Bilanz und Perspektiven. 1. Aufl. 2017. 172 Seiten, 30 cm, kt.  
 978-3-86884-574-7 **€ 16,80**
- Meyer, Tim / Ferrauti, Alexander / Kellmann, Michael / Pfeiffer, Mark  
**Regenerationsmanagement im Spitzensport.** REGman – Ergebnisse und Handlungsempfehlungen. 1. Aufl. 2016. 122 Seiten, 30 cm, kt.  
 978-3-86884-589-1 **€ 32,50**
- Muckenhaupt, Manfred (Hrsg.)  
**Wissen im Hochleistungssport.** Perspektiven und Innovationen. Veröffentlichung anlässlich des Internationalen Symposiums Informations- und Wissensmanagement im Hochleistungssport 24. Juni–26. Juni 2010 Heinrich-Fabri-Institut Blaubeuren. 1. Aufl. 2011. 180 Seiten, 21 cm, kt.  
 978-3-86884-475-7 **€ 26,00**
- Müller, Elena (Red.)  
**Top-Forschung für den Sport.** BISp-Symposium. Bonn, 15. April 2010. 1. Aufl. 2011. 154 Seiten, 21 cm, kt.  
 978-3-86884-474-0 **€ 24,00**
- Neumann, Gabriele (Hrsg.)  
**Sportpsychologische Betreuung des deutschen Olympia- & Paralympic-teams 2008.** Erfolgsbilanzen-Erfahrungsberichte-Perspektiven. 1. Aufl. 2009. 156 Seiten, 29,7 cm, kt.  
 978-3-86884-492-4 **€ 28,80**
- Neumann, Gabriele (Red.)  
 Talentdiagnose und Talentprognose im Nachwuchsleistungssport. 2. BISp-Symposium: Theorie trifft Praxis. 1. Aufl. 2009. 444 Seiten, 21 cm, kt.  
 978-3-86884-497-9 **vergriffen**
- Neumann, Gabriele / Stehle, Peter (Hrsg.)  
**Fußball interdisziplinär.** Zur Optimierung der Prävention, Rehabilitation und Wiederverletzungsprophylaxe von Knie- und Sprunggelenksverletzungen. 1. Aufl. 2009. 86 Seiten, 29 cm, kt.  
 978-3-86884-490-0 **vergriffen**

Pilz, Gunter A. / Behn, Sabine / Harzer, Erika / Lynen v. Berg, Heinz / Selmer, N.

**Rechtsextremismus im Sport.** In Deutschland und im internationalen Vergleich. 2. ergänzte Aufl. 2014. 204 Seiten, 29,7 cm, kt.

978-3-86884-506-8 € 28,00

Quade, Karl / Rebel, Mirjam / Müller, Elena (Red.)

**Volleyball.** BISp-geförderte Forschungsprojekte der Jahre 2005 bis 2009. 1. Aufl. 2009. 142 Seiten, 29,7 cm, kt.

978-3-86884-483-2 **vergriffen**

Shakhlina, Larissa J. G.

**Medizinisch-biologische Grundlagen des sportlichen Trainings von Frauen.** 1. Aufl. 2010. 302 Seiten, 21 cm, kt.

978-3-86884-479-5 € 24,50

Stehle, Peter (Hrsg.)

**BISp-Expertise: „Sensomotorisches Training – Propriozeptives Training“** Band I. 1. Aufl. 2009. 128 Seiten, 21 cm, kt.

978-3-86884-498-6 € 19,80

Stehle, Peter (Hrsg.)

**BISp-Expertise: „Sensomotorisches Training – Propriozeptives Training“** Band II. 1. Aufl. 2009. 96 Seiten, 21 cm, kt.

978-3-86884-499-3 € 16,80

Stoll, Oliver / Achter, Mathias / Jerichow, Mareike

**Vom Anforderungsprofil zur Intervention.** Eine Expertise zu einem langfristigen sportpsychologischen Beratungs- und Betreuungskonzept für den Deutschen Schwimm-Verband e.V. (DSV). 1. Aufl. 2010. 82 Seiten, 29,7 cm, kt.

978-3-86884-473-3 € 22,80

Weidig, Thorsten

**Erfolgsfaktor Trainer.** Das Trainerverhalten in Spiel- und Wettkampfpausen auf dem Prüfstand. 1. Aufl. 2010. 194 Seiten, 21 cm, kt.

978-3-86884-478-8 € 18,80

Wenhold, Franziska / Elbe, Anne-Marie / Beckmann, Jürgen

**Fragebogen zum Leistungsmotiv im Sport.** Achievement Motives Scale-Sport (AMS-Sport). 1. Aufl. 2009. 58 Seiten, 29,7 cm, kt.

978-3-86884-494-8 € 16,00

Wenhold, Franziska / Elbe, Anne-Marie / Beckmann, Jürgen

**Volitionale Komponenten im Sport.** Fragebogen zur Erfassung volitionaler Komponenten im Sport (VKS). 1. Aufl. 2009. 50 Seiten, 29,7 cm, kt.

978-3-86884-509-9 € 16,00

Wetterich, Jörg / Eckl, Stefan / Schabert, Wolfgang

**Grundlagen zur Weiterentwicklung von Sportanlagen.** 1. Aufl. 2009. 326 Seiten, 21 cm, kt.

978-3-86884-505-1 € 28,90

Wippert, P. M. / Brückner, M. / Fließner, M.

**Der Nationale Dopingpräventionsplan: eine Potenzialeinschätzung.** Forschungsbericht zur Evaluation des NDPP. 1. Aufl. 2014. 150 Seiten, 29,7 cm, kt.

978-3-86884-592-1 € 38,00



**Alexander Hagg** ist Postdoc an der Hochschule Bonn-Rhein-Sieg am Institut für Technik, Ressourcenschonung und Energieeffizienz. Er forscht zu Mehrlösungsoptimierung mithilfe evolutionärer und generativer Lernverfahren, insbesondere in der Strömungsdynamik.



**Alexander Asteroth** ist Professor für Informatik an der Hochschule Bonn-Rhein-Sieg und Direktor des Instituts für Technik, Ressourcenschonung und Energieeffizienz. Sein Arbeitsschwerpunkt ist die Anwendung probabilistischer und evolutionärer maschineller Lernverfahren, insbesondere in der Sportinformatik.



**Christian Rasche** ist wissenschaftlicher Mitarbeiter am Institut für Sportwissenschaft der Johannes Gutenberg-Universität Mainz. Er forscht zu antagonistischer Leistungsmodellierung, Athletenmonitoring und Bewegungserkennung mittels Inertialsensorik.



**Kevin Bach** ist wissenschaftlicher Mitarbeiter an der Hochschule Bonn-Rhein-Sieg. Er forscht an probabilistischen Modellen zur Vorhersage von Herzfrequenz und Trainingseffekten im Anwendungsbereich Ausdauersport.



**Mark Pfeiffer** ist Professor am Institut für Sportwissenschaft der Johannes Gutenberg-Universität Mainz (Abt. „Theorie und Praxis der Sportarten“). Arbeitsschwerpunkte: Analyse sportlichen Trainings, Sportspielforschung, Kinder- und Jugendsport, Regeneration.

**SPORTVERLAG *Strauß***  
Neuhaus 12 · 53940 Hellenthal  
info@sportverlag-strauss.de  
www.sportverlag-strauss.de

ISBN: 978-3-86884-551-8



9 783868 845518