



## Überblicksbeitrag

# QUALITATIVE ANALYSE VON PROZESSEN IM SPORT MIT HILFE VON METHODEN DES SOFT COMPUTING

JÜRGEN PERL  
UNIVERSITÄT MAINZ

Die Analyse komplexer Prozesse, wie sie z. B. bei Spielen oder Bewegungen ablaufen, kann in quantitativer oder in qualitativer Weise durchgeführt werden. Vereinfacht gesagt berechnet die quantitative Analyse charakteristische numerische Kenngrößen, Verteilungen oder strukturelle Zusammenhänge. Geeignete Werkzeuge hierfür sind verfügbar und werden eingesetzt; dabei werden Prozessdynamiken und Interaktionen von Systemkomponenten aber häufig vernachlässigt. Im Gegensatz dazu versucht die qualitative Analyse, Typen von Interaktion, zeitabhängige Dynamik, Schlüsselaktivitäten und spezielle Auffälligkeiten zu entdecken. Obwohl die Ergebnisse solcher qualitativen Analysen häufig nicht verallgemeinert werden können, verbessern sie doch oft das Verständnis grundlegender Phänomene und komplexen Systemverhaltens. Diese Idee hat zu einem "Paradigmenwechsel" geführt, bei dem harte mathematische Kriterien wie Präzision, Vollständigkeit und Determiniertheit von Analysemethoden ersetzt wurden durch weiche Kriterien: Die Methoden des "Soft Computings" sollen nicht präziser und vollständiger sein als notwendig oder sinnvoll; Berechnungsprozesse dürfen statistisch variieren, solange die Ergebnisse akzeptable Lösungen repräsentieren. Die Schwerpunkte des Soft Computing liegen gegenwärtig in den Bereichen Künstliche Neuronale Netze, Evolutionäre Algorithmen und Fuzzy Modellierung. Die bisher in diesen Schwerpunkten entwickelten Methoden haben sich für die Analyse komplexer dynamischer System als sehr hilfreich erwiesen. Der Grund hierfür ist u.a. das Zusammenwirken von vergleichsweise hoher Genauigkeit mit geringem Aufwand und guter Anpassungsfähigkeit.

Schlüsselwörter: Spielanalyse, Prozessorientierung, Fuzzy-Modellierung, Evolutionäre Algorithmen, Künstliche Neuronale Netze, Antagonistische Dynamik

*Analyses of complex processes, as for instance well-known from games or motions, can be done in a quantitative or in a qualitative way. Briefly spoken, quantitative analysis calculates characteristic numbers, distributions or structural relations; appropriate tools are available and used. Process dynamics and interaction of system components normally are neglected. In contrast, qualitative analysis tries to recognize types of interaction, time-dependent dynamics, key activities and striking features. Although the results of qualitative analyses often cannot be generalized, they nevertheless help for a better understanding of basic phenomena and complex system behavior. This idea has led to a "change of paradigms", where sharp mathematical criteria like absolute precision, completeness and determinism of analysis methods have been replaced by "soft" criteria: Methods of "soft computing" do not have to be more precise and complete than necessary or useful; the calculation process may vary statistically, if only the results represent acceptable solutions. Currently, soft computing more or less deals with artificial neural networks, evolutionary algorithms and*

*fuzzy modeling. The developed methods have proved to be helpful in case of complex problems, where they not least are able to combine comparably high precision with surprisingly low effort and good adaptability*

Keywords: Game analysis, process orientation, fuzzy modeling, evolutionary algorithms, artificial neural networks, antagonistic dynamics

## Modellbildung und Soft Computing

Modellbildung ist ein grundlegender Arbeitsbereich nicht nur in der Informatik oder der Sportwissenschaft. Immer wenn das Verhalten komplexer Systeme zu analysieren ist – im Fall technischer Systeme genauso wie im Fall biologischer Systeme – liegt das grundlegende Problem in der Modellierung der Systemstruktur und der Interaktion der Systemkomponenten. Eine Reduktion auf einen einfachen Vergleich von Eingabe- mit Ausgabedaten ist weder für eine quantitative noch für eine qualitative Analyse hinreichend. Erst wenn die Systemdynamik transparent und gut verstanden ist, gibt es eine Chance, auf der Basis des gegenwärtigen Zustandes und der geplanten Aktivitäten das zukünftige Systemverhalten vorherzusagen. Modellbildung und Simulation können das Verständnis komplexer Systeme ganz allgemein wesentlich verbessern und darüber hinaus speziell im Sportbereich die Entwicklung und Optimierung von Trainingsplänen oder Handlungsstrategien unterstützen, ohne den Athleten zu belasten.

Entsprechend den Erfahrungen der Informatik kann auch die Sportwissenschaft sowohl aus der Erfassung, Analyse und Handhabung von Daten als auch aus dem Einsatz von Modellbildung und Simulation erhebliche Vorteile ziehen. Die erzielbaren Verbesserungen meinen dabei nicht nur "mehr" oder "schneller". Eine verbesserte Qualität des Daten-Handlings erlaubt insbesondere auch die Verwendung und Weiterentwicklung neuer Konzepte und Methoden – wie z. B. bei der Prozess-Orientierung und im Bereich Soft Computing: Prozess-Orientierung bedeutet, dass nicht eine isolierte Aktivität einen isolierten Zustandswechsel

bewirkt, sondern dass Sequenzen von Aktivitäten oder Ereignissen entsprechend Sequenzen von Zuständen bewirken, wobei speziell Puffer und Transfers eine zentrale Rolle für verzögerte Effekte spielen. Es ist dabei von besonderer Bedeutung, dass solche Verzögerungseffekte durch systeminterne Dynamik gesteuert werden und dadurch einer Beurteilung durch statistische Methoden – wie z. B. einer Kreuz-Korrelations-Analyse beobachtbarer externer Effekte – sehr oft nicht zugänglich sind. Dies ist offensichtlich z. B. in den Fällen von Spiel-Analyse oder Rehabilitation, gilt aber in analoger Weise für Bewegungs- oder Leistungs-Analyse.

Ein wichtiges Gebiet der Informatik, das sich mit neuen Ansätzen und Konzepten der Analyse komplexer Systemdynamik befasst, ist Soft Computing – worin ein Paradigmenwechsel in Richtung biologische Systeme zum Ausdruck kommt, bei dem Determinismus durch Zufälligkeit, Präzision durch Unschärfe und Vollständigkeit durch Flexibilität und Anpassungsfähigkeit ersetzt wird. So können z. B. Bewegungsmuster oder taktisch-strategische Muster in Spielen einfacher mit Hilfe Neuronaler Netze analysiert und verglichen werden; Interaktion und Kommunikation in Spielen kann besser mit Hilfe von Fuzzy-Modellen beschrieben werden; Lösungen in hochdimensionalen Problemräumen wie etwa optimale Bahnen oder Kurse können deutlich schneller mit Hilfe Evolutionärer Algorithmen gefunden werden. Schließlich unterstützen Soft Computing und die neuen Paradigmen ein stärker ganzheitliches Verständnis komplexer Systeme und ihrer Interaktionen (vgl. Balague & Torrents, 2005). Ob und in welchem Maße diese Ansätze und ihre Methoden im Einzelfall aber konventionellen Alternativen vorzuziehen sind, ist selbstverständlich nicht pauschal zu entscheiden, sondern hängt von der jeweiligen konkreten Problemstellung ab. So wäre z. B. eine statistische Clusteranalyse einer netzgestützten Analyse gegebenenfalls vorzuziehen, wenn etwa die weiteren Vorteile des Netzansatzes wie Dimensionsreduzierung oder vorwissenfreies Lernen (vgl. 2.3) nicht relevant sind. Gegen den Einsatz von Evolutionären Algorithmen kann ihr stochastisches Element sprechen, das eine präzise Reproduzierbarkeit der Ergebnisse verhindert. In nicht zu komplexen Problemfällen können hier einfache enumerative Algorithmen mit akzeptablem Aufwand verlässlichere Lösungen berechnen. Schließlich gilt für diese Ansätze wie auch für den Fuzzy-Ansatz, dass ein sinnvoller Einsatz ein fundiertes methodisches Wissen sowie ein gewisse Erfahrung bezüglich der Anwendbarkeit der Methoden voraussetzt.

Im Folgenden werden für die exemplarisch dargestellten Konzepte und Methoden des Soft Computing kurz die grundlegenden Ideen skizziert und die Umsetzbarkeit in die Praxis jeweils an einigen Projekten demonstriert, die das Spektrum

der möglichen Anwendungen exemplarisch aufzeigen sollen. In Anbetracht der sehr großen Zahl von belegten Anwendungsbeispielen im Sport (vgl. z. B. die Referenzliste in Schöllhorn (2004) allein für Bewegungsanalyse mit Hilfe Neuronaler Netze) war für die Auswahl hier entscheidend, dass die Beispiele den roten Faden der Darstellung verdeutlichen, und dass dabei die grundlegenden Aspekte der jeweiligen Ansätze reflektiert wurden. Für eine konkrete Nutzung der dargestellten Ansätze ist die Beschäftigung mit weitergehenden Quellen (z. B. in der angegebenen Literatur) unumgänglich.

### *Analyse von Prozess-Mustern*

Speziell im Fall von Prozessen – hier zu verstehen als zeitabhängige ereignisbezogene Veränderung von Systemzuständen – darf die Analyse nicht beschränkt werden auf isolierte Zustände oder Ereignisse, sondern muss sowohl den aktuellen Zustand als auch die vergangenen Zustände und Ereignisse in Betracht ziehen. Zukünftiges Verhalten eines Systems kann nicht vorausgesagt werden, ohne die Vergangenheit des Systems in seiner internen Wirkungsdynamik und seinem externen Wechselwirkungs-Kontext verstanden zu haben. Daher kann zukünftiges Verhalten nicht (oder jedenfalls nur unzureichend) mit Hilfe statistischer Wahrscheinlichkeiten aus der Vergangenheit abgeleitet werden. Darüber hinaus muss speziell bei der Beschäftigung mit menschlichem Verhalten und Interagieren wie etwa in Sportspielen ein möglicher Widerspruch zwischen regelbasiertem Verhalten (Spielregel, Taktik, Strategie) und situationsabhängigen Entscheidungen (Spontaneität, Variabilität, Kreativität) in Betracht gezogen werden. Insgesamt wird so deutlich, dass Prozess-Analyse im Sport, insbesondere unter den Aspekten Prognose und taktisch-strategische Planung, sich nicht auf numerisch-quantitative und generalisierende Ansätze beschränken kann, sondern auch qualitative und individuenorientierte Konzepte verwenden muss.

Im Folgenden werden hierzu einige Ansätze vorgestellt, die exemplarisch entsprechende Ideen verdeutlichen sollen, ohne allerdings die Fülle der publizierten Beispiele auch nur ansatzweise repräsentieren zu können (vgl. hierzu z. B. die Beiträge in der Reihe "Sport und Informatik" des Bundesinstituts für Sportwissenschaft sowie Nachfolgepublikationen und die Beiträge im "International Journal of Computer Science in Sport").

### *Fuzzy-Modellierung*

In der mathematisch-logischen Modellierung ist die Zugehörigkeit eines Objektes zu einer Menge eine 0-1-Information – das Objekt gehört entweder zur Menge, oder es gehört nicht dazu. Wird z. B. Leistung eines Sportlers auf einer Skala von 1 bis 10

10 bewertet, und stehen die Bewertungen 1 bis 5 für schlechte, die von 6 bis 10 für gute Leistungen, dann ist auf Grund der erreichten Punktzahl eindeutig geklärt, ob der Sportler das Prädikat "gut" oder das Prädikat "schlecht" erhält. Diese Eindeutigkeit gilt grundsätzlich unabhängig von einer tatsächlichen Untersuchung dieser Zugehörigkeit.

Die statistische Modellierung dagegen unterscheidet zwischen der Zuordnung vor und der Zuordnung nach dem Zugehörigkeitstest: Nach dem Test entspricht die eindeutige 0-1-Zuordnung der des mathematisch-logischen Modells. Vor dem Test wird zusätzliche Information aus dem aktuellen Kenntnisstand der verfügbaren Mengen gewonnen, indem aus der Relation zwischen ihren Umfängen eine Erwartung auf die Art der Zuordnung abgeleitet wird. Sind im obigen Beispiel bislang 60 Sportler als "gut" und 20 als "schlecht" bewertet worden, so besteht eine Erwartung von 3 zu 1 oder von 75%, dass der neue Test das Ergebnis "gut" hat. In dieser statistischen Modellierung wird also eine uneindeutige oder unscharfe Vorinformation durch den Test in eine eindeutige 0-1-Nachinformation überführt.

Die Fuzzy-Modellierung verwendet ebenfalls eine uneindeutige oder unscharfe (= fuzzy) Zuordnung, die aber, vergleichbar mit dem mathematischen Modell und anders als im statistischen Modell, Bestandteil des Objektes relativ zum Bewertungsschema ist und so zwar durch den Test erkannt, aber nicht verändert wird. Allerdings unterscheidet sich dieses Bewertungsschema auch grundsätzlich von dem des mathematischen Modells: Während im Beispiel des mathematischen Modells alle Skalenwerte von 1 bis 5 das selbe Bewertungsattribut "schlecht" erhalten, entsprechend für "gut", werden im Fuzzy-Modell differenzierte Bewertungsattribute im Sinne von Zugehörigkeitsgraden vergeben. Auf diese Weise könnte z. B. die Punktzahl 6 auf einer von 0 bis 1 reichenden Zugehörigkeitsskala mit dem Zugehörigkeitsgrad 0,3 das Attribut "schlecht" und mit dem Zugehörigkeitsgrad 0,5 das Attribut "gut" tragen. Dem Sportler, der die Punktzahl 6 erreicht hat, werden so mit den entsprechenden Zugehörigkeitsgraden sowohl das Attribut "schlecht" als auch das Attribut "gut" zugeordnet. Dieser Ansatz vermeidet also die scharfen Entweder-Oder-Entscheidungen an Klassengrenzen und spiegelt so eher die realitätsnäheren unscharfen Einordnungen wider, die Prädikate wie z.B. "kaum", "etwas", "ziemlich" oder "überwiegend" für die Charakterisierung verwenden. Weil die Verteilungskonzepte des statistischen und des Fuzzy-Ansatzes häufig verwechselt werden, soll noch einmal nachdrücklich betont werden, dass die Objekt-spezifische Fuzzy-Verteilung der Zugehörigkeitsgrade (im Beispiel für den Sportler nach dem Test mit der Bewertung 6:  $[(\text{schlecht}; \text{gut})] = [0,3; 0,5]$ ) nichts mit der Grundgesamtheits-spezifischen statistischen Häufigkeits-Verteilung

(im Beispiel für den Sportler vor dem Test:  $[(\text{schlecht}; \text{gut})] = [0,25; 0,75]$ ) zu tun hat. Für ausführlichere Informationen zum Fuzzy-Konzept und zum Arbeiten mit Fuzzy-Modellen siehe z. B. Gerla (2001) und Kruse, Gebhardt und Klawohn (1993).

Ein erster Versuch, diesen Ansatz zur Modellierung von Verhaltensprozessen im Sportspiel zu nutzen, wurde Mitte der 1990er Jahre für Handball unternommen (vgl. Abbildung 1). Die Idee bestand darin, die Position eines Spielers durch einen unscharfen Bereich möglicher Positionen zu ergänzen, der zu Beginn einer Aktion divergiert (Entscheidungsspielraum) und zu ihrem Ende konvergiert (Zielorientierung). Das Ergebnis waren Fuzzy-Prozessmuster, die typisches Verhalten deutlich besser modellierten als Zeitreihen von Positionen mit (scheinbar) mehr oder weniger zufälligen Koordinaten (s. Perl, 1997 und Liesegang, 1996).

Als weiteres Beispiel für den Einsatz von Fuzzy-Modellierung im Sportspiel ist ein Ansatz zur taktischen Vorbereitung zu nennen, der darin besteht, mit Hilfe von Fuzzy-Logik die Zuordnung von Spielern zu taktischen Positionen zu optimieren (s. Wiemeyer, 2003): Der zentrale Punkt hierbei war, eine möglichst gute Übereinstimmung zwischen dem Leistungsprofil des Spielers und dem Anforderungsprofil der Position herzustellen. Dabei sind die Bedeutungen der die Profile formenden Attribute wie z. B. Übersicht oder Anspielfähigkeit für die fragliche Position offensichtlich nicht mathematisch determiniert und somit für ein mathematisch exaktes Verfahren nicht verwendbar. Mit Hilfe von Fuzzy-Verteilungen über Bewertungskategorien wie "gering", "mäßig", "gut", "hoch", "sehr", mit der die Bedeutung einer Fähigkeit für die Position unscharf charakterisiert wird, kommt man dagegen zu schlüssigen Fuzzy-Auswahlregeln wie z. B. "Wenn der Spieler eine gute Übersicht hat und sehr anspielbereit ist, dann sollte er im Aufbau eingesetzt werden." Eine weitere Möglichkeit, derartige Unschärfe zu Verbesserung des Informationsgewinns einzusetzen, besteht bei der Diagnose von Fehlern, z. B. im Fall von Bewegungsprozessen (s. Schiebl, 2001): Sind mehrere Fehler für die Nicht-Optimalität einer Bewegung verantwortlich, so kann sich der Grad der jeweiligen Verantwortlichkeit über die verschiedenen Fehler im Sinne einer Fuzzy-Zugehörigkeit verteilen. Unabhängig davon kann aber auch eine statistische Vertei-




Abbildung 1: Bewegungsmuster von Angriffshandlung (dunkelgrau) und Abwehrhandlung (hellgrau) im Handball. Links: Spieler-Positionen; Mitte: Positionen ergänzt durch Fuzzy-Bereiche; Rechts: Prozess aus Fuzzy-Bewegungsmustern (Perl, 1997, S. 86-87).

lung existieren, mit der z. B. die Wahrscheinlichkeit beschrieben wird, dass ein Fehler hauptsächliche Ursache für die beobachtete Störung ist. Eine zentrale Idee des Fuzzy-Ansatzes, nämlich Präzision zu reduzieren, um mehr (verwertbare) Information zu erhalten, wird auch in den folgenden Ansätzen in unterschiedlicher Form wieder aufgegriffen.

### Evolutionäre Algorithmen

Die üblichen mathematisch-informatischen Methoden zur konkreten Problemlösung bestehen darin, aus der Menge der möglichen Lösungen die für die konkrete Problemsituation geeignete(n) durch Berechnungen und/ oder algorithmische Eingrenzungsschritte (z. B. selektive Suche) zu bestimmen. Dabei heißt "geeignet", dass das Ergebnis präzise allen Anforderungen an die Lösung genügt. Im Fall einer Optimierungsaufgabe kann das z. B. heißen, dass die Lösung zwar nicht unbedingt zu 100% einen gewünschten Zielwert erreichen muss, dass sie dann aber jedenfalls im Rahmen einer vorgegebenen, erlaubten Abweichung liegen muss. In der Praxis sind selbst solche Vorgaben häufig noch zu restriktiv, und Lösungen zu solchen Vorgaben wären möglicherweise nicht einmal in die Praxis umsetzbar – etwa wenn die numerische Präzision einer biomechanischen Bewegungsempfehlung in der Bewegungssteuerung des ausführenden Sportlers so nicht repräsentiert ist. Dies führt auf das Problem der Optimierung von Lösungen unter komplexen Randbedingungen: So sind z. B. für das Problem, in einem Langstreckenlauf eine bestimmte Zielzeit  $T$  zu erreichen, die optimalen Zwischenzeiten  $t_i$  bei festgelegten Teilstrecken  $S_i$  interessant. Ob diese Zwischenzeiten sinnvoll sind und zu der intendierten Gesamtzeit führen, hängt von der zeitdynamischen Interaktion zwischen der jeweils gelaufenen Geschwindigkeit und der daraus resultierenden Ermüdung ab. Diese Interaktion definiert eine Zielfunktion  $f$ , die die Folgen  $t = (t_1, t_2, \dots, t_n)$  der Zwischenzeiten  $t_i$  auf die Ergebniszeit  $T = f(t)$  abbildet, die aber wegen ihrer Kompliziertheit kaum eine geschlossene mathematische Optimierung zulässt, und deren Lösungen selbst im positiven Fall zunächst bezüglich ihrer Umsetzbarkeit überprüft werden müssten. Anstatt nun in der konventionellen Weise aus  $f$  und  $T$  die optimale Folge  $t$  zu berechnen, versucht ein evolutionärer Algorithmus, aus verschiedenen Lösungsmöglichkeiten durch sog. Rekombination der Einträge allmählich die brauchbaren gegenüber den unbrauchbaren Teilen zu selektieren. Dabei werden z. B. aus zwei solchen Zwischenzeit-Folgen  $(a_1, \dots, a_n)$  und  $(b_1, \dots, b_n)$  durch Austausch von Teilfolgen zwei neue Folgen  $(a_1, \dots, a_k, b_{k+1}, \dots, b_n)$  und  $(b_1, \dots, b_k, a_{k+1}, \dots, a_n)$  gebildet und bezüglich der damit gemäß der Zielfunktion  $f$  erreichbaren Ergebniszeiten und z.B. weiterer Kontextbedingungen wie der

Umsetzbarkeit verglichen. Die besseren Folgen werden behalten und die schlechteren aussortiert. Ist die Menge der Folgen, mit denen gestartet wird (wegen der Beziehung des Ansatzes zur biologischen Evolution auch Start-Population genannt) genügend repräsentativ, dann kann bereits das fortgesetzte Rekombinieren und Selektieren zu einer genügend genauen Lösung führen (so, wie sich in der Natur eine Spezies über die Zeit durch Kreuzung und Selektion an die jeweilige Umweltbedingung anpasst) – aber nicht immer: Isolierte Populationen können durch Inzucht in Sackgassen geraten, aus denen sie nur noch durch äußere Eingriffe wie z. B. Mutationen herauskommen. Daher wird auch bei den evolutionären Algorithmen das Konzept von Rekombination und Selektion ergänzt durch das der Mutation, bei der durch stochastische Veränderungen einzelner Einträge versucht wird, den Lösungsprozess aus etwaigen Sackgassen herauszuführen.

Evolutionäre Algorithmen stellen in komplexen Problemsituationen häufig die einzige praktikable Möglichkeit der algorithmischen Behandlung dar. Allerdings müssen dabei, wie oben schon erwähnt, gegebenenfalls Abstriche bei der erzielbaren Genauigkeit gemacht werden. Zudem ist wegen des stochastischen Elementes der Mutation eine präzise Reproduzierbarkeit der Ergebnisse über unabhängige Bearbeitungen nicht gegeben. Für ausführlichere Informationen zu Ansatz und Einsatz der Evolutionären Algorithmen siehe z. B. Eiben und Smith (2003) und Weicker (2002). Eines der in der Literatur behandelten Beispiele befasst sich mit der Bestimmung einer optimalen Spur beim Abfahrtslauf im alpinen Ski (s. Seifriz, 2001). Auf den ersten Blick scheint das ein Problem zu sein, das mit Hilfe mathematisch-physikalischer Gleichungen gelöst werden kann. Das ist einerseits korrekt, da man in der Tat derartige Gleichungen für ein adäquates Modell benötigt. Andererseits gibt es eine sehr große Anzahl mehr oder weniger optimaler Lösungen, die sich nur in Winzigkeiten unterscheiden, und es würde einen immensen Aufwand machen, die wirklich allerbeste Lösung zu finden – die dann möglicherweise aus spezifischen Kontextbedingungen nicht einmal praktisch in den Lauf umgesetzt werden könnte. Der für die Spur-Berechnung gewählte Ansatz besteht darin, Positions-Sequenzen (in Abbildung 2: die Folge der als "Knoten" markierten Schlüsselpositionen des Laufs) mit Hilfe eines Evolutionären Algorithmus durch Rekombination, Selektion und Mutation zu optimieren. Dabei ist es die Aufgabe der Bewertungsfunktion, zum einen mit Hilfe der zugehörigen mathematisch-physikalischen Gleichungen den jeweiligen Zeitbedarf zu berechnen und so die Positions-Sequenzen mit minimalem Zeitbedarf zu ermitteln. Zum anderen kann die Bewertungsfunktion gegebenenfalls bereits im Vorfeld Lösungsversuche selektieren, die mit zu-

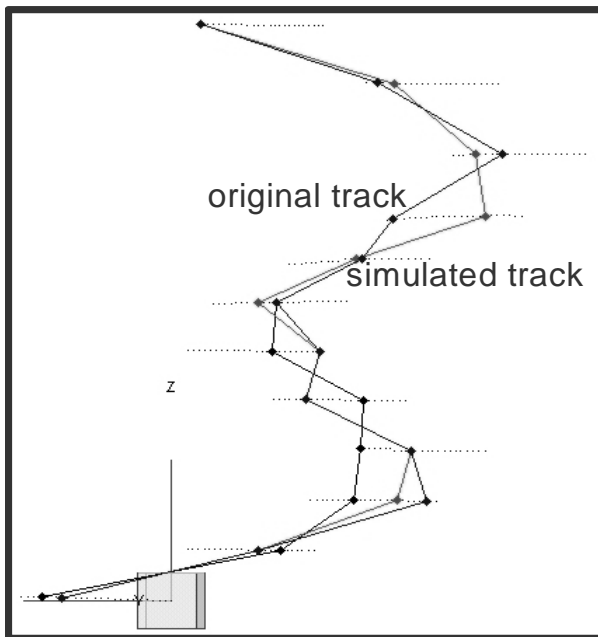


Abbildung 2: Eine Original-Spur im Abfahrtslauf verglichen mit einer simulierten Spur (mit einigen kleineren Variationen), die mit Hilfe Evolutionärer Algorithmen berechnet wurde. Obwohl die originale und die simulierte Spur erheblich voneinander abweichen, sind die benötigten Zeiten etwa gleich, wobei die simulierte Spur ein wenig schneller ist (modifiziert nach Seifriz, 2001, S. 92).

sätzlichen Kontextbedingungen kollidieren und daher nicht umsetzbar sind.

Wie oben bereits ausgeführt, liefert dieser Ansatz nicht unbedingt die eine beste Lösung. Stattdessen bietet er häufig eine Kollektion von dicht am Optimum liegenden Lösungen an, die einen Eindruck von möglichen Variationen vermitteln und so speziell auch die individuelle Adaptation unterstützen.

Eine weitere Möglichkeit, Evolutionäre Algorithmen zur Optimierung von Prozessen einzusetzen, besteht im Sportspiel: So kann z. B. versucht werden, eine Handlungsfolge in Form technisch-taktischer Maßnahmen optimal auf das Verhalten des Gegners abzustimmen. Zwar ist der Ansatz der Spieltheorie zur vollständigen Analyse und Bewertung aller möglichen Abläufe der deutlich umfassendere Ansatz für eine Strategie-Optimierung. Leider ist dieser Ansatz aber auch deutlich aufwendiger und die Ergebnisse lassen sich ebenso schwer in die Praxis umsetzen wie exakt berechnete Bahnkurven im Abfahrtslauf. Für den Einsatz eines Evolutionären Algorithmus werden (entsprechend der Positions-Sequenzen im Abfahrtslauf) die möglichen Folgen von Aktionen betrachtet, die, abhängig von den jeweiligen Gegenreaktionen, mehr oder weniger erfolgreich sind. Mit dieser Erfolgsbewertung als Zielfunktion lassen sich die Aktionsfolgen dann wieder durch Rekombination, Selektion und Mutation bezüglich des Erfolges optimieren (s. Stein, 2004). Schließlich sei

noch auf eine interessante Anwendung hingewiesen, die zwar weniger mit Prozessen zu tun hat, dafür aber die breite Einsatzmöglichkeit des Ansatzes Evolutionärer Algorithmen demonstriert: Bei der Konzipierung von Sportgeräten sind häufig eine große Anzahl von Parametern und Bedingungen zu berücksichtigen, die durchaus auch miteinander kollidieren können. Mathematische Lösungsansätze wie etwa der der linearen Optimierung stoßen dabei relativ schnell an ihre Grenzen. Für das Beispiel der Konzipierung eines Bogens für das Bogenschießen wurde gezeigt, dass auch solche komplexen Konstruktionsprobleme mit Hilfe Evolutionärer Algorithmen außerordentlich befriedigend gelöst werden können (s. Kittel, Edelmann-Nusser & Vajna, 2006).

Die bisher vorgestellten Ansätze der Fuzzy-Modellierung und der Evolutionären Algorithmen haben u.a. gezeigt, dass mathematisch-quantitative Lösungsmethoden gegebenenfalls durch unscharfe und/ oder qualitative Konzepte ergänzt werden müssen, um die Ergebnisse in der Praxis verwendbar zu machen. Diese Möglichkeit der Ergänzung oder sogar Ersetzung quantitativer Modellierung mit ihrem Fokus auf numerischen Indikatoren durch qualitative Modellierung mit ihrem Fokus auf Mustern und Typen soll im Folgenden exemplarisch an Hand von Künstlichen Neuronalen Netzen demonstriert werden:

#### Künstliche Neuronale Netze und Muster-Analyse

Ein Künstliches Neuronales Netz besteht aus sog. Neuronen, die in ihren Funktionen der Reizaufnahme und -weiterleitung sehr vereinfacht den natürlichen Neuronen nachgebildet sind, und einem System von Verbindungen für den Reiztransport, die sehr vereinfacht den Dendriten, Axonen und Synapsen nachgebildet sind. Das ursprüngliche Ziel des Ansatzes war der modellhafte Transfer der Interaktionsdynamik von Neuronen-Systemen auf technische Informationserfassung und Informationsklassifizierung. Inzwischen hat sich das Modell vom Original weitgehend gelöst und bildet ein eigenständiges Konzept für Informationserfassung und -bewertung. Der Vorgang der Informationserfassung, das sog. Lernen, kann überwacht oder unüberwacht erfolgen und charakterisiert so zwei sehr unterschiedliche Netztypen und Einsatzformen: Beim überwachten Lernen (Netztypen: Back-Propagation- oder Feed-Forward-Netze) ist eine Trainingsinformation zusammen mit der korrekten Bewertung als Input gegeben. Die Aufgabe besteht darin, die Zuordnung von Information und Bewertung mit Hilfe von Überwachung und Korrektur zu lernen, um sie anschließend auch auf nicht-trainierte Information (richtig) anwenden zu können. Für das Beispiel der Zwischenzeiten-Optimierung aus 2.1 könnte ein solches Netz lernen, welche der bisherigen Muster in welchen Situationen erfolgreich waren, und auf dieser Basis

dann Bewertungen für neue Problemfälle ableiten. Die erfolgreiche Überwachung des Lernens setzt also ein erhebliches Vorwissen über bekannte Fälle und deren Bewertungen voraus. Ist dieses Vorwissen nicht vorhanden, kann unüberwachtes Lernen (Netztypen: Kohonen Feature Map [KFM], Self Organizing Map [SOM]) zum Ziel führen, bei dem das Netz die Trainingseingaben nicht bewertet, sondern selbständig nach Ähnlichkeit gruppiert. Das Ergebnis sind Klassen oder Typen von Eingaben, die einer Strukturierung der Eingabemenge dienen und gegebenenfalls durch eine semantische Bewertung (z. B. Typbezeichnung) ergänzt werden können. Im Sport treten Fragestellungen, die mit diesem Ansatz bearbeitet werden können, überwiegend im Bereich der Analyse von Prozessmustern auf, z.B. bei der systematischen Erfassung von Angriffs- und Abwehrprozessen im Sportspiel, bei der Klassifizierung von Bewegungsmustern oder auch bei der Erkennung möglicher taktisch-strategischer Muster: So könnte die Zwischenzeiten-Optimierung von oben davon abhängig sein, welche Typen von Lauferteilungen von den jeweiligen Gegnern zu erwarten sind. Die Analyse im Sinne einer Klassifizierung solcher taktischen Laufmuster wäre dann Aufgabe eines KFM oder SOM. Für ausführlichere Informationen zum Thema Künstliche Neuronale Netze siehe u.a. Köhle (1990), Kohonen (1995), Perl und Dauscher (2006) sowie Polani und Uthmann (1993).

Wie die folgenden Beispiele zeigen, können derartige Muster die komplexen Originaldaten auf ihre wesentlichen Informationsanteile reduzieren – z. B. auf Typen, Repräsentanten oder Trajektorien der zeitabhängigen Prozesse – und so die Prozessanalyse unterstützen.

Abbildung 3 zeigt einen Ansatz zur Analyse taktischen Verhaltens in Squash mit Hilfe Künstlicher Neuronaler Netze. Die linke Abbildung zeigt die aus dem Spiel gewonnene Information – nämlich die Sequenz der Schlagpositionen der einzelnen Spieler. Die rechte Graphik zeigt ein Neuronales Netz, dessen Neuronen charakteristische Positionsfolgen (repräsentiert durch schwarze Kreise) und die aus ihnen gebildeten zentralen Typen (markierte Bereiche) gelernt haben. Das taktische




Abbildung 3: Links: Folge von Schlagpositionen. Rechts: Neuronales Netzwerk mit einigen markierten Neuronen (schwarze Kreise), die charakteristische Abspielfolgen im Squash repräsentieren. Bereiche hauptsächlichlicher Abspiel-Typen wie „long-line“ oder „cross“ sind durch schwarze und graue Linien markiert (Perl, 2002b, Abbildungen 9,10 und 11).




Abbildung 4: Netz-basierte Trajektorien-Darstellung vom Ergometer-Rudern: Jeder Knoten einer Trajektorie repräsentiert die 2-dimensionale Projektion des korrespondierenden hochdimensionalen Vektors biomechanischer Attribute (z.B. Gelenkposition, Geschwindigkeit, Kraft) im jeweiligen Zeitpunkt (Perl, 2006b, S. 32).

Verhalten der Spieler lässt sich quantitativ aus der Häufigkeit ablesen, mit der bestimmte Positionsfolgen aktiviert wurden. Qualitativ kann das taktische Verhalten durch den Wechsel zwischen den zentralen Typen mit Hilfe von Trajektorien abgebildet werden (vgl. Perl, 2002b). Der wesentliche Vorteil des Neuronalen Netzes ist hier, dass es die sehr große Menge möglicher Abspielfolgen selbständig auf eine kleine Menge charakteristischer Trajektorien reduzieren kann. Auch Bewegungsabläufe können in dieser Weise mit Hilfe Neuronaler Netze klassifiziert und repräsentiert werden, wenn man die Neuronen entsprechend ihrer zeitlichen Anordnung durch eine Trajektorie verbindet. Dabei kommt als weiterer Vorteil des Netz-Ansatzes zum Tragen, dass die in der Regel hochdimensionale Bewegungsinformation pro Beobachtungszeitpunkt auf eine nur 2-dimensionale Repräsentation durch das korrespondierende Neuron reduziert werden kann und so eine graphische Darstellung durch eine Trajektorie überhaupt erst ermöglicht.

Abbildung 4 demonstriert, wie die Trajektorien von Ruderer A und B unter den Aspekten der intra-individuellen Stabilität und der inter-individuellen Ähnlichkeit verglichen werden können: Man erkennt, dass alle Trajektorien untereinander ziemlich ähnlich sind, dass die von Ruderer A aber stabiler als die von Ruderer B sind. Ein genauerer Blick zeigt allerdings, dass die Trajektorien in einigen Bereichen spezifische Unregelmäßigkeiten zeigen, die Anlass für eine eingehendere Analyse z. B. mit Hilfe von Videobildern sein können (vgl. Perl, 2004a; Perl & Baca, 2003). Netzgestützte Prozessanalysen sind in den verschiedensten Bereichen des Sports erfolgreich durchgeführt worden. Stellvertretend seien hier die Spielanalyse (vgl. Perl & Lames, 2000), die Motorik (vgl. Bauer & Schöllhorn, 1997; Schöllhorn & Perl, 2002; Schöllhorn, 2004), das Schwimmen (vgl. Edelman-Nusser, Hohmann & Henneberg, 2002) sowie die Rehabilitation (vgl. Rebel, 2004) genannt.

Trajektorien auf einem Netzwerk können schließlich auch dazu benutzt werden, technisch-






Abbildung 5: Netz-basierte Trajektorien von Verteidigungs-Aktivitäten im Volleyball (Frauen, Deutschland gegen Italien): Die hoch-dimensionale Mannschfts-Konstellation (Positionen der Spielerinnen zum jeweiligen Zeitpunkt) sind repräsentiert durch 2-dimensionale Knoten. Die Knoten sind durch graue Quadrate umrahmt, deren Größe die Auftrittshäufigkeit der betreffenden Konstellation codiert. Schwarze Umrahmungen kennzeichnen Bereiche ähnlicher Konstellations-Typen (Jäger, Perl & Schöllhorn, 2007, Abbildungen 3 und 12).

taktisches Verhalten in einem Spiel transparenter zu machen (vgl. Abbildung 5), hier am Beispiel von Spielerkonstellationen im Volleyball. Wie man aus den Trajektorien erkennen kann, zeigen das deutsche (Ger) und das italienische (Ita) Team deutlich unterschiedliches Verhalten, repräsentiert durch die zentralen Konstellationstypen (schwarz markierte Bereiche) und Art und Häufigkeiten der Konstellationswechsel: Das deutsche Team bewegt sich in einer etwas "nervös" wirkenden Weise häufig zwischen verschiedenen Konstellationstypen, um die endgültige Aufstellung einzunehmen, während das italienische Team die endgültige Aufstellung sehr schnell findet und dann nur in kleinen Schritten die Adaptation optimiert (s. Perl, 2003; Jäger, Perl und Schöllhorn, 2007). Für einen ebenfalls netzbasierten Ansatz zur Analyse von Konfigurationen im Volleyball vergleiche Jäger und Schöllhorn (2006).

Komplexe Konfigurationen im Angriffs- und Abwehrverhalten von Mannschaften werden aktuell u.a. für Handball und Fußball untersucht. Im Beispiel Handball (vgl. Pfeiffer & Perl, 2006) werden dabei schwerpunktmäßig die vom Neuronalen Netz für verschiedene Nationalmannschaften erkannten Muster auf taktisch-strategische Auffälligkeiten vergleichend untersucht und daraus Schächen und Stärken der jeweiligen Spielstärken abgeleitet. Im Beispiel Fußball (s. Lees, Barton & Kershaw, 2003; Leser, 2006a; Leser, 2006b) werden die Möglichkeiten der Video- und Computerunterstützten Spielanalyse insgesamt dargestellt und dabei speziell untersucht, welche einerseits unterschiedlichen und andererseits sich ergänzenden Informationen Markov- und Netz-Analysen über die Prozesse im Spiel liefern können. Gerade in Leser (2006) wird deutlich, wie sehr eine verbesserte Technologie der Datenerfassung z. B. durch automatisierte Positionserfassung ihr Potential erst durch verbesserte und gegebenenfalls un-

konventionelle Analysemethoden gewinnbringend in die Praxis umsetzen kann.

Abschließend soll mit Lernprozessen noch kurz auf eine spezielle Form von Prozessen eingegangen werden, die ihre Bedeutung aus der Tatsache beziehen, dass sich hierfür vergleichende Analysen mit dem Lernverhalten von Künstlichen Neuronalen Netzen und so gegebenenfalls auch Simulationen von natürlichen Lernprozessen auf Neuronalen Netzen ermöglichen lassen.

Ein erster Ansatz hierzu (s. Perl & Weber, 2004) beschäftigte sich mit der Frage, wie optimale Trainingsstrategien für Neuronale Netze aussehen könnten, wenn einerseits konkurrierende und andererseits sich ergänzende Lernziele gesetzt werden. Die Ergebnisse, die übrigens mit Hilfe Evolutionärer Algorithmen gefunden werden konnten, zeigen für die Netze eine teilweise verblüffende qualitative Übereinstimmung mit natürlichen Lernmustern, so dass sich hieraus der Versuch einer Optimierung von Lernprozessen mit Hilfe von Simulation auf Neuronalen Netzen anbietet. Zu einem analogen Ergebnis kam ein zweiter Ansatz (vgl. Memmert & Perl, 2005; Memmert & Perl, 2006; Perl, Memmert, Bischof & Gerharz, 2006). Hierbei wurden zum einen Prozesse des Kreativitätslernens mit Hilfe von Neuronalen Netzen analysiert; das Ergebnis war die Erkennung und Unterscheidung von Lerntypen. Zum anderen konnten mit dem Lerninput aus den Praxistests Neuronale Netze trainiert werden und zeigten dann in dieser Simulation ein Lernverhalten, das dem der Probanden vergleichbar war.

Die für diese Lernprozess-Analysen benutzten Netze verwendeten, anders als die üblichen Netze vom KFM-Typ, spezielle Dynamiken für das räumliche Wachstum (d. h. für die Anpassung von Neuronenzahl und -positionen an den Reizraum, vgl. Fritzsche, 1997) und das kontinuierliche Lernen (d.h. die Neuronen-intern geregelte Anpassung des Trainingszustandes, vgl. Perl (2001)). Dabei wird für das kontinuierliche Lernen ein Ansatz verwendet, der eine physiologische Adaptation mit Hilfe einer antagonistischen Dynamik modelliert, und der ursprünglich für die Analyse von Belastungs-Leistungs-Interaktionen im Trainingsprozess entwickelt wurde (s. Perl, 2002a). Dieser Ansatz soll, auch wenn er nicht wie die oben vorgestellten Ansätze zentral den Paradigmen des Soft Computing zuzurechnen ist, wegen seiner anscheinend übergreifenden Bedeutung im Folgenden abschließend kurz dargestellt werden.

#### Antagonistische Dynamik

Im Zusammenhang mit Prozessen spielen häufig Interaktionen zwischen Komponenten eine Rolle, deren Wirkungen nicht eindeutig bewertet werden können, weil sie sich zeit- oder kontextabhängig verändern können. Unter einer antagonistischen Dynamik soll eine derartige Wechselwirkung ver-

standen werden, bei der zwei unterschiedliche Wirkungen der gleichen Ursache durch eine zeitliche oder kontextuelle Versetzung eine regelnde Funktion bekommen. So kann ein Bewegungsimpuls als Ursache eine beschleunigende und eine bremsende Wirkung auslösen, die in ihrer gegenseitigen Kontrolle die resultierende Bewegung zielorientiert regeln. Ein einfaches Modell zur Beschreibung zeitabhängiger antagonistischer Dynamik besteht darin, die jeweiligen Einzelwirkung spezifisch zu verzögern, so dass die mit der einen Wirkungsform antagonistisch konkurrierende andere Wirkungsform nicht sofort, sondern erst in einem entsprechend veränderten Systemzustand aktiviert wird. Im Beispiel des Performance-Potential-Meta-Modell (PerPot) wird dieser Ansatz speziell für Analyse und Planung von Trainingsprozessen vorgestellt (vgl. Perl, 2002a).

Planung benötigt Vorhersagbarkeit von Verhalten und erfordert daher ein Verständnis der Dynamik des komplexen Systems "Athlet" unter dem Aspekt der Belastungs-Leistungs-Interaktion. Wenn wenigstens die Trends dieser Interaktion simuliert werden könnten (vgl. Abbildung 6), würde dies die Entwicklung besserer Trainingspläne bedeutend unterstützen und damit zu viel Überbelastung und kontraproduktives Training vermeiden helfen. Das Modell, das in Abbildung 6 vorgestellt wird, basiert auf der antagonistischen Wirkung von Trainingsbelastungen, die einerseits die Leistung (vorübergehend) reduziert, andererseits aber als Stimulus notwendig ist, um die Leistung zu erhöhen.

Detailliertere Information zum Begriff "Antagonistische Dynamik" und insbesondere bezüglich der Vorhersagbarkeit von Leistung und der Planung von Trainingsbelastung findet sich in Perl (2004b) und Perl (2005). Dass ein solcher Ansatz auch für deutlich komplexere Wechselwirkungen wie etwa die in einem Mannschaftsspiel verwendbar ist, belegen erste Ergebnisse für Handball (s. Lames & Perl, 2006; Perl, 2006a): Unter der Annahme, dass die Aktivitäten der einen Mannschaft




Abbildung 6: Trainingsbelastung pro Tag (schwarze Punktlinie unten: Anzahl Trainingsstunden) resultiert in einen verzögerten Leistungs-Output (hellgraue Punktlinie: Hämoglobinkonzentration). Die Interaktion von Belastung und Leistung hängt ab von einer komplexen internen Dynamik, die mit Hilfe eines antagonistischen Modells simuliert werden kann (dunkelgraue Punktlinie) (Perl, 2004b, Abbildung 3).

auf die gegnerische Mannschaft mit unterschiedlichen Zeitverzögerungen sowohl leistungsreduzierenden Druck ausüben als auch leistungssteigernde Motivation erzeugen, konnten Spielverlaufsdynamiken in Form von Torerfolg in Abhängigkeit vom Ballbesitz mit Hilfe eines PerPot-Deriva analysiert und typisiert werden.

### Zusammenfassung und Ausblick

Geeignete Modellbildung und Simulation zusammen mit Prozess-Analyse und Soft Computing können dazu beitragen, das Verhalten komplexer Systeme besser zu verstehen. Hierfür bieten Soft Computing und weitergehende unkonventionelle Ansätze ein umfangreiches Instrumentarium für die Analyse dynamischer Prozesse an, das insbesondere auch im Bereich Sport eingesetzt und dort die erprobten quantitativen Ansätze durch neuere qualitative Ansätze ergänzen kann.

Wie die exemplarisch dargestellten Anwendungen und speziell die Ausblicke der angeführten aktuellen Projekte zeigen, lassen die Orientierung an Prozessen, ein vertieftes Verständnis von Modellen sowie eine verbesserte Erfassung und Verarbeitung von Information erwarten, dass komplexe Dynamiken im Sport nicht nur besser gerechnet, sondern auch besser verstanden werden können. Eine besondere Rolle scheinen hierbei die Neuronalen Netze zu spielen, die mit ihrer speziellen Fähigkeit der Informationsreduktion und -verdichtung eine Voraussetzung dafür liefern, komplexe Zusammenhänge und Prozesse transparenter zu machen und nachvollziehbar abzubilden.

### Literatur

- Balague, N. & Torrents, C. (2005). Thinking before Computing: Changing approaches in Sports Performance. *International Journal of Computer Science in Sport*, 4 (2), 5-13.
- Bauer, H.-U. & Schöllhorn, W. I. (1997). Self-Organizing Maps for the Analysis of Complex Movement Patterns. *Neural Processing Letters*, 5, 193-199.
- Eiben, A.E. & Smith, J.E. (2003). *Introduction to Evolutionary Computation*. Berlin-Heidelberg-New-York: Springer.
- Edelmann-Nusser, J., Hohmann, A. & Henneberg, B. (2002). Modeling and prediction of competitive performance in swimming upon neural networks. *European Journal of Sport Science*, 2 (2), 1-10.
- Fritzke, B. (1997). A self-organizing network that can follow non-stationary distributions. In *Proceedings of ICANN97, International Conference on Artificial Neural Networks* (pp. 613-618). New-York: Springer.
- Gerla, G. (2001). *Fuzzy Logic: Mathematical Tools for Approximate Reasoning*. Norwell: Kluwer Academic Publishers.
- Jäger, J., Perl, J. & Schöllhorn, W. (2007). Analysis of players' configurations by means of artificial neural networks. *International Journal of Performance Analysis of Sport*, 3 (7), 90-103.
- Jäger, J. M. & Schöllhorn, W. I. (2006). Analyse spieltaktischer Positionsmuster im Volleyball mit künstlichen Neuronalen Netzen. In J. Raab et al. (Hrsg.), *Zukunft der Sportspiele: fördern, fordern, forschen* (Bd. 2, S. 203-206). Flensburg: University Press.
- Kittel, K., Edelmann-Nusser, J. & Vajna, S. (2006). Optimierung von Bogenmittelteilen aus verschiedenen Metalllegierungen mit Evolutionären Algorithmen. In J. Edelmann-Nusser & K.



- Witte (Hrsg.), *Sport und Informatik IX* (S. 263-268). Aachen: Shaker.
- Köhle, M. (1990). *Neuronale Netze*. Wien: Springer.
- Kohonen T. (1995). *Self-Organizing Maps*. Berlin–Heidelberg–New-York: Springer.
- Kruse, R., Gebhardt, J. & Klawohn, F. (1993). *Fuzzy Systeme*. Stuttgart: BG Teubner.
- Lames, M. & Perl, J. (2006). Prozessmodellierung von Handballspielen – stochastische Beschreibung und antagonistische Modellierung. In M. Raab, A. Arnold, K. Gärtner, J. Köppen, C. Lempertz, N. Tielemann, H. Zastrow (Hrsg.), *Zukunft der Sportspiele: fördern, fordern, forschen* (Bd. 2, S. 186-190). Flensburg: University Press.
- Lees, A., Barton, B. & Kerschaw, L. (2003). The use of Kohonen neural network analysis to establish characteristics of technique in soccer kicking. *Journal of Sports Sciences*, 21, 243-244.
- Leser, R. (2006a). Prozessanalyse im Fußball mittels Neuronaler Netze. In M. Raab, A. Arnold, K. Gärtner, J. Köppen, C. Lempertz, N. Tielemann, H. Zastrow (Hrsg.), *Zukunft der Sportspiele: fördern, fordern, forschen* (Bd. 2, S. 199-202). Flensburg: University Press.
- Leser, R. (2006b). *Systematisierung und praktische Anwendung der computer- und digitalvideo-gestützten Sportspielanalyse*. Dissertation, Universität Wien, Zentrum für Sportwissenschaft und Universitätssport.
- Liesegang, W. (1996). Ein Fuzzy-Modell für Angriff-Abwehr-Interaktionen im Handball. In K. Quade (Hrsg.), *Anwendungen der Fuzzy-Logik und Neuronaler Netze*, S. 33-40. Köln: Strauß.
- Memmert, D. & Perl, J. (2005). Game Intelligence Analysis by Means of a Combination of Neural Networks and Variance-Analysis. *International Journal of Computer Science in Sport*, 4, (1), 29-39.
- Memmert, D. & Perl, J. (2006). Identifikation und Generierung kreativer Lernverläufe mit Hilfe dynamischer Neuronaler Netze. In M. Raab, A. Arnold, K. Gärtner, J. Köppen, C. Lempertz, N. Tielemann, H. Zastrow (Hrsg.), *Zukunft der Sportspiele: fördern, fordern, forschen* (Schriftenreihe Human Performance and Sport 1, S. 78). Flensburg: University Press.
- Perl, J. (1997). Möglichkeiten und Probleme der computerunterstützten Interaktionsanalyse am Beispiel Handball. In J. Perl (Hrsg.), *Sport & Informatik V* (S. 74-89). Köln: Strauß.
- Perl, J. (2001). DyCoN: Ein dynamisch gesteuertes Neuronales Netz zur Modellierung und Analyse von Prozessen im Sport. In J. Perl (Hrsg.), *Sport & Informatik VIII* (S. 85-98). Köln: Strauß.
- Perl, J. (2002a). Adaptation, Antagonism, and System Dynamics. In G. Ghent, D. Kluka & D. Jones (Eds.), *Perspectives – The Multidisciplinary Series of Physical Education and Sport Science 4* (pp. 105-125). Oxford: Meyer & Meyer Sport.
- Perl, J. (2002b). Game analysis and control by means of continuously learning networks. *International Journal of Performance Analysis of Sport*, 2, 21-35.
- Perl, J. (2003). Einsatz Neuronaler Netze in der Sportspielanalyse. In B. Strauß, N. Hagemann, M. Tietjens & G. Gabriela Falkenberg-Gurges (Hrsg.), *sport goes media*. (S. 125). Hamburg: Czwalina.
- Perl, J. (2004a). A Neural Network approach to movement pattern analysis. *Human Movement Science*, 23, 605-620.
- Perl, J. (2004b). PerPot – a meta-model and software tool for analysis and optimization of load-performance-interaction. *International Journal of Performance Analysis of Sport*, 4 (2), 61-73.
- Perl, J. (2005). Dynamic Simulation of Performance Development: Prediction and Optimal Scheduling. *International Journal of Computer Science in Sport*, 4 (2), 28-37.
- Perl, J. (2006a). Qualitative analysis of team interaction in a game by means of the load-performance-metamodel PerPot. *International Journal of Performance Analysis in Sport*, 6 (2), 34-51.
- Perl, J. (2006b). Einsatz künstlicher neuronaler Netze zur Mustererkennung im Sport. In A. O. Effenberg (Hrsg.), *Bewegungs-Sonifikation und Musteranalyse im Sport*. (S. 29-36). Cuvillier: Göttingen.
- Perl, J. & Baca, A. (2003). Application of neural networks to analyze performance in sports. In E. Müller, H. Schwameder, G. Zallinger & V. Fastenbauer (Eds.), *Proceedings of the 8th annual congress of the European College of Sport Science*, S. 342. Universität Salzburg, Institut für Sportwissenschaft.
- Perl, J. & Dauscher, P. (2006). Dynamic Pattern Recognition in Sport by Means of Artificial Neural Networks. In R. Begg & M. Palaniswami (Eds.), *Computational Intelligence for Movement Science* (pp. 299-318). Hershey–London–Melbourne–Singapore: Idea Group Publishing.
- Perl, J. & Lames, M. (2000). Identifikation von Ballwechsellauftypen mit Neuronalen Netzen am Beispiel Volleyball. In W. Schmidt & A. Knollenberg (Hrsg.), *Sport-Spiel-Forschung: Gestern. Heute. Morgen*. (S. 211-215). Hamburg: Czwalina.
- Perl, J. & Weber, K. (2004). A Neural Network approach to pattern learning in sport. *International Journal of Computer Science in Sport*, 3 (1), 67-70.
- Perl, J., Memmert, D., Bischof, J. & Gerharz, Ch. (2006). On a First Attempt to Modelling Creativity Learning by Means of Artificial Neural Networks. *International Journal of Computer Science in Sport*, 5 (2), 33-37.
- Pfeiffer, M. & Perl, J. (2006). Analysis of Tactical Structures in Team Handball by Means of Artificial Neural Networks. *International Journal of Computer Science in Sport*, 5 (1), 4-14.
- Polani, D. & Uthmann, Th. (1993). *Neuronale Netze - Grundlagen und ausgewählte Aspekte der Theorie*. Technischer Bericht 2/92. Universität Mainz, Institut für Informatik.
- Rebel, M. (2004). *Wenn der Kopf in die Knie geht – Analyse von Rehabilitationsverläufen nach Kreuzbandrekonstruktionen*. Bonn: Kovac.
- Schiebl, F. (2001). Fuzzy-Technikdiagnose – Der Einsatz wissenschaftlicher Fuzzy-Systeme zur Fehlerdiagnose sportlicher Bewegungstechniken. In J. Perl (Hrsg.), *Sport und Informatik VIII* (S. 113 – 122). Köln: Strauß.
- Schöllhorn, W. & Perl, J. (2002). Prozessanalysen in der Bewegungs- und Sportspießforschung. *Spectrum der Sportwissenschaften*, 14 (1), 30-52.
- Schöllhorn, W. (2004). Applications of artificial neural nets in clinical biomechanics. *Clinical Biomechanics*, 19 (9), 876-898.
- Seifriz, F. (2001). *Simulation im alpinen Skisport*. Berlin: dissertation.de.
- Stein, T. (2004). *Entwicklung von Spielstrategien im Tennis mit Hilfe genetischer Algorithmen*. Diplomarbeit. Technische Universität Darmstadt, Institut für Sportwissenschaft.
- Weicker, K. (2002). *Evolutionäre Algorithmen*. Stuttgart, Leipzig, Wiesbaden: BG Teubner.
- Wiemeyer, J. (2003). Who should play in which position in soccer? Empirical evidence and unconventional modelling. *International Journal of Performance Analysis in Sport*, 3 (1), 1-18.
- Zachry, T., Wulf, G., Mercer, J., & Bezodis, N. (2005). Increased movement accuracy and reduced EMG activity as the result of adopting an external focus of attention. *Brain Research Bulletin*, 67, 304-309.

---

Überblicksbeitrag erhalten: 09.02.2007

Überarbeiteten Überblicksbeitrag erhalten: 11.09.2007

Überblicksbeitrag akzeptiert: 11.09.2007

Überblicksbeitrag veröffentlicht: 26.09.2007