

Künstliche Neuronale Netz-Modelle in der Sportwissenschaft

Das Beschreiben und Analysieren von Phänomenen im Sport ist notwendigerweise mit dem Prozess der Modellierung verbunden. Auf einer abstrakten Ebene wird die Wahl der Sprache zur Beschreibung und Analyse der Phänomene genutzt, um reale Phänomene anhand einer Anzahl an subjektiv ausgewählten Symbolen vereinfacht abzubilden. Die Wahl der Symbole erfolgt dabei durch eine aktive und subjektive Entscheidung eines Forschers anhand einer begrenzten Anzahl an Kriterien, die zu einer vereinfachten Abbildung des realen Objekts führen (Stachowiak, 1973). Entsprechend ist jede Beschreibung eines Phänomens eine Abbildung eines Modell-Originals (reales Objekt) auf ein (vereinfachtes) Modell und ist Teil des Prozesses einer jeden wissenschaftlichen Modellierung. In diesem Prozess folgt auf die Festlegung des Modellzwecks eine Auswahl adäquater Modellvariablen, die als Ein- und Ausgangsvariablen unterschiedlicher Formen von Modellen dienen. Die Kriterien zur Auswahl der Variablen sind vielfältig und reichen von „nur messbar“ bis zu hoch sophistischen mathematischen Extraktions-Prozeduren.

Unabhängig von der Art des Modells dient es nach Abschluss des Konstruktionsprozesses zur Simulation der Realität. Der Unterschied zwischen dem simulierten Ergebnis und der Realität wird hierbei oft als ein Maß für die Güte eines Modells verwendet. Üblicherweise wurden dazu lineare statistische Ansätze für umfangreiche Datenansätze vorgeschlagen. Nichtlineare Anwendungen wie künstliche neuronale Netze (im Folgenden KNN) fanden zunächst außerhalb der Sportwissenschaft umfangreiche Anwendungen z. B. im Gesundheitsbereich (vgl. Begg, Kamruzzaman & Sarker, 2006) und in der klinischen Forschung (vgl. Schöllhorn, 2004), bevor sie unterstützt durch Perls Aktivitäten und Entwicklungen in der Sportwissenschaft Verbreitung fanden. Ursprünglich wurden KNN in der Mitte des 20. Jahrhunderts entwickelt und während der 80er und frühen 90er Jahre mit großem Erfolg weiterentwickelt und in unterschiedlichen Bereichen angewandt (Kohonen, 2001). Das Ziel des Beitrags ist die Darstellung von Möglichkeiten der Anwendungen von überwachten und unüberwachten KNN zur Modellierung von Fragestellungen im Sport (zu den allg. Grundlagen der KNN-Modellierung im Sport vgl. Schöllhorn, Jäger & Janssen 2008; zur Theorie der KNN vgl. z. B. Zell, 1996).

1 Anwendungen überwachter KNN im Sport

Zu den frühen Anwendungen überwachter Netze im Sport zählen international die Modellierungen von Herren, Sparti, Aminian und Schultz (1999). Sie nahmen die dreidimensionalen Beschleunigungen am unteren Rücken und an der Ferse während des Laufens auf. Ausgewählte Parameter der Körperbeschleunigung dienten

als Eingangsvariablen zum Training eines MLPs (Multi-Layer Perceptrons), um Outdoor Laufmuster zu erkennen und die Geschwindigkeiten bei unterschiedlichen Steigungen zu bestimmen. Zehn männliche und zehn weibliche Probanden rannten 18mal auf Straßen mit unterschiedlichen Steigungen und variierenden Geschwindigkeiten. Für das Training des MLP wurden 12 Datensätze verwendet, wohingegen die sechs restlichen Datensätze zur Validierung des KNN-Modells genutzt wurden. Ein KNN diente zur Bestimmung der Geschwindigkeit, das andere für die Steigung. Von ursprünglich 28 Parametern wurden 10 Eingangsparameter aufgrund ihrer Korrelationen mit der Laufgeschwindigkeit und Steigung verwendet. Der mittlere quadratische Fehler für die Geschwindigkeit lag bei 0.12 m/s und 0.-0.014 radiant (~1.4 % Fehler) für die Steigung. Die multiple Regressionsanalyse erlaubte im Vergleich dazu eine ähnliche Präzision für die Geschwindigkeit, jedoch ein schlechteres Ergebnis für die Steigung (2.6 % Fehler).

Ein ähnlicher KNN-Ansatz wurde von Maier (Maier, Wank, Bartonietz & Blickhan, 2000; Maier, 2001; Maier, Meier, Wagner & Blickhan, 2000; Maier, Wank & Bartonietz, 1998) für die Vorhersage von Wurfedistanzen beim Kugelstoß und Speerwurf anhand der Abflugbedingungen gewählt. Bei Vernachlässigung der Windgeschwindigkeit und Aerodynamik der Kugel in Verbindung mit einer konstanten Abflughöhe von 2 m wurde ein MLP mit zwei Eingabe- und einem Ausgabeneuron sowie zwei verborgenen Schichten mit 5 bzw. 3 Neuronen trainiert. Die Eingabevariablen waren der Abflugwinkel und die Abfluggeschwindigkeit. Die Ausgabevariable war die jeweilige Stoßweite. Mit Hilfe des physikalischen Modells des schiefen Wurfs wurden Daten mit Abstoßwinkeln zwischen 30 und 55° sowie Abfluggeschwindigkeiten zwischen 9 und 15 m/s generiert. Die Winkel wurden in 1° Schritten variiert und die Geschwindigkeit in Schritten von 1 m/s. Von allen berechneten Kombinationen wurden 100 zufällig ausgewählte Stöße zum Training des MLP genutzt. Der Lernalgorithmus wurde gestoppt, wenn der Fehler unter 0.1 m lag. Um die Wahrscheinlichkeit zu minimieren, ein lokales Minimum in der Lösungslandschaft des Netzes zu finden, wurde der Prozess 200mal mit zufällig ausgewählten Startgewichten für die Neuronen wiederholt. Die simulierte Stoßweite führte zu einem mittleren Fehler von nur 2.5 %. Diese Anwendung eines KNN dient als ein Beispiel für implizite physikalische Modellierung, ohne das physikalische Prinzip explizit zu beschreiben.

Für ein KNN-Modell, das die Speerwurfweite vorhersagen sollte, wurden ebenfalls physikalische Abflugbedingungen des Speers als Eingabeparameter verwendet: drei Abflugwinkel des Speeres (Abflug-, Anstell- und Angriffswinkel) und die Abfluggeschwindigkeit. Als Ausgabeparameter diente die Flugweite des Speers. Die Ein- und Ausgabeparameter wurden bei 98 realen Würfen aufgenommen. Der Bereich der Abfluggeschwindigkeit des Speeres für die Trainingsdaten lag zwischen 21.3 m/s und 31.4 m/s, für den Abflugwinkel zwischen 25° und 42°, für den Angriffswinkel zwischen 23° und 49° und für den seitlichen Angriffswinkel zwischen -2° und 28°. Mehrere MLPs mit zwei verborgenen Schichten mit zwischen 2 und 8 Neuronen in jeder Schicht wurden auf Effektivität getestet. Das Kriterium für die Netzleistung war der mittlere Standardfehler. Das KNN-Modell war in der Lage die

aktuellen Flugweiten des Speers mit einer Abweichung vom gemessenen Wert von 2.5 % vorherzusagen.

Künzell (1996) trainierte eine Variante eines Jordan Netzes (Jordan & Rumelhart, 1992) darauf, die Formel des schiefen Wurfes am Beispiel des Positionswurfes im Basketball von 3, 5, 7 und 9 Metern implizit möglichst gut zu lernen. Er kombinierte dies mit unterschiedlichen Lernstrategien, die geordnet nach dem offerierten sequentiellen Rauschumfang am Kontext-Interferenz-Lernen mit verschiedenen großen Blöcken und Wiederholungen orientiert waren. Zu große Übungsblöcke führten zu schlechteren Leistungen in Anwendungs- und Transferszenarien des Netzes. Zu ähnlich interpretierbaren Ergebnissen gelangt bereits Horak (1992), der ein Multi-layer Perzeptron darauf trainiert, für einen ballistischen Wurf zu einer gewünschten Flugweite eine entsprechende Kraft zu „berechnen“. Für hohe Kontext-Interferenz ergeben sich in der Aneignungsphase schlechtere, jedoch in der Transferphase bessere Leistungen, was den Ergebnissen aus Feldstudien nicht widerspricht. Da sich das Training künstlicher neuronaler Netze jedoch deutlich von biologischem Lernen unterscheidet, kann in beiden Pilotansätzen allerdings nur bedingt ein Rückschluss auf reales Lernen gezogen werden, da im eigentlichen Sinne zwar ein Modell entwickelt wurde, das Phänomene der Realität abbildet, jedoch keinen Umkehrschluss auf das reale Funktionieren der Realität zulässt. So benötigt das von Künzell mit hoher Kontext-Interferenz trainierte Netz die längste Trainingszeit. Reale Studien mit hohem Variationsumfang während des Lernprozesses widersprechen dem jedoch (Schöllhorn, Mayer-Kress, Newell, & Michelbrink, 2009).

Die Untersuchung des Zusammenhangs zwischen Abflugparametern und der Bewegung des Athleten war Gegenstand von Yans Arbeitsgruppe (Yan & Li, 2000; Yan & Wu, 2000). 20 globale und 33 lokale Technikparameter wurden als Eingabevariablen gewählt. Die Ausgabevariablen des MLPs mit einer verborgenen Schicht waren der Winkel und die Geschwindigkeit der Kugel beim Abflug. Die Fehler zwischen Netzausgabe und den gemessenen Abflugbedingungen wurden mit denen einer Regressionsanalyse verglichen. Der Fehler bei KNN lag im Mittel 25 % bis 30 % unter dem der Regressionsanalyse. Interessanterweise waren die Fehler beider Methoden kleiner als die Unschärfen, die durch manuelle Abtastung entstehen (Bartlett, 2006).

Der Einfluss von Trainingsinterventionen auf die Wettkampfleistung im Schwimmen wurde von Edelmann-Nusser, Hohmann und Henneberg (2002) mit Hilfe von drei MLPs untersucht. Jedes Netz hatte dabei zehn Eingabe-, zwei verborgene und ein Ausgabeneuron. Die Eingabevariablen waren Trainingsinhalte und -umfänge aus Trainingseinheiten zwei bis vier Wochen vor dem eigentlichen Wettkampf. Die Trainingsdaten waren durch geschwommene Kilometer in der jeweiligen Intensität sowie durch die Anzahl der Stunden spezifischen Kraft- und Konditionstrainings quantifiziert. Die Ausgabevariable war die Wettkampfleistung von 19 Wettkämpfen in ca. 3 Jahren. Die Untersuchung endete mit einem Vorhersagefehler von 0.05 s, bei einer Schwimmzeit von 2:12,64 min.

Janssen, Schöllhorn, Lubienetzki, Fölling, Kokenge und Davids (2008) setzten MLPs für die Erkennung individueller Charakteristiken beim Gehen ein. Hier stellte sich heraus, dass MLPs in der Lage waren, aufgrund der hohen Individualität des menschlichen Gangs, die kinetischen Gangmuster von 38 Probanden zu 98.5 % der richtigen Person zuzuordnen.

Jäger, Alichmann und Schöllhorn (2003) konnten mit Hilfe eines einfachen Perzeptrons anhand der kinetischen Gangmuster von vier Probanden zu 100 % erkennen, ob es sich um normale oder ermüdete Gangmuster der Probanden handelte. Ermüdung wurde in dieser Studie durch individuelle Zusatzgewichte erreicht, die die spunggelenks- bzw. kniestreckende Muskulatur bis zur subjektiven Erschöpfung belasteten.

Ein weiterer Eindruck von der Vielseitigkeit der Anwendungsmöglichkeiten künstlicher neuronaler Netze in der Sportwissenschaft kann aus Anwendungen in der Sportmedizin und der Sportsoziologie abgeleitet werden. Ringwood (1999) modellierte die anaerobe Schwelle auf der Grundlage der Arbeits- und Herzfrequenzdaten während eines Conconi-Tests. Auf der Basis demographischer und physiologischer Herzfrequenzdaten wurde durch Värinämö und Mitarbeiter ein Modell zur aeroben Fitness mithilfe von zwei seriell verbundenen MLPs angenähert (Värinämö, Mäkikallio, Tullppo & Rönning, 1998; Värinämö, Nissila Mäkikallio, Tulppo & Rönning, 1996). Der Erfolg von Nationalmannschaften bei olympischen Sommerspielen wurde von Condon, Golden und Wasil (1999) auf der Basis soziologischer Parameter wie Lebenserwartung, Stromverbrauch oder Kindersterblichkeitsrate modelliert.

2 Anwendungen unüberwacht lernender neuronaler Netze im Sport

Erste Anwendungen selbstorganisierender KNN können Mitte der 90er Jahre des letzten Jahrhunderts gefunden werden. Grob können die Anwendungen in drei Gruppen unterteilt werden, wobei meist gemischte Modelltypen konstruiert wurden. In einem Typus werden die selbstorganisierenden KNN zur Reduktion der hohen Dimension von Daten genutzt. Im zweiten Typus werden die hochdimensionalen Daten klassifiziert und im dritten Typus werden Gruppierungen von zwei unterschiedlichen Sätzen von Variablen in Bezug auf das gleiche Phänomen verglichen.

2.1 Dimensionsreduktion

Obwohl alle Arten von Daten als Eingabevariablen fungieren können, unabhängig von der Zeitstruktur, modellieren die meisten Anwendungen von SOMs (Self-Organising Maps) Bewegungstechniken oder Spielzüge in Mannschaftsspielen, die auf multiplen Intensitäts-Zeitverläufen (zeitkontinuierlich) als Eingabevariablen dienen, anstelle von Variablenausprägungen an ausgewählten Zeitpunkten (zeitdiskret). Bei der Modellierung von zeitskalenabhängigen Qualitäten können zwei Ansätze unterschieden werden (Schöllhorn & Bauer, 1995). Eine schematische Darstellung ist Abbildung 1 zu entnehmen.

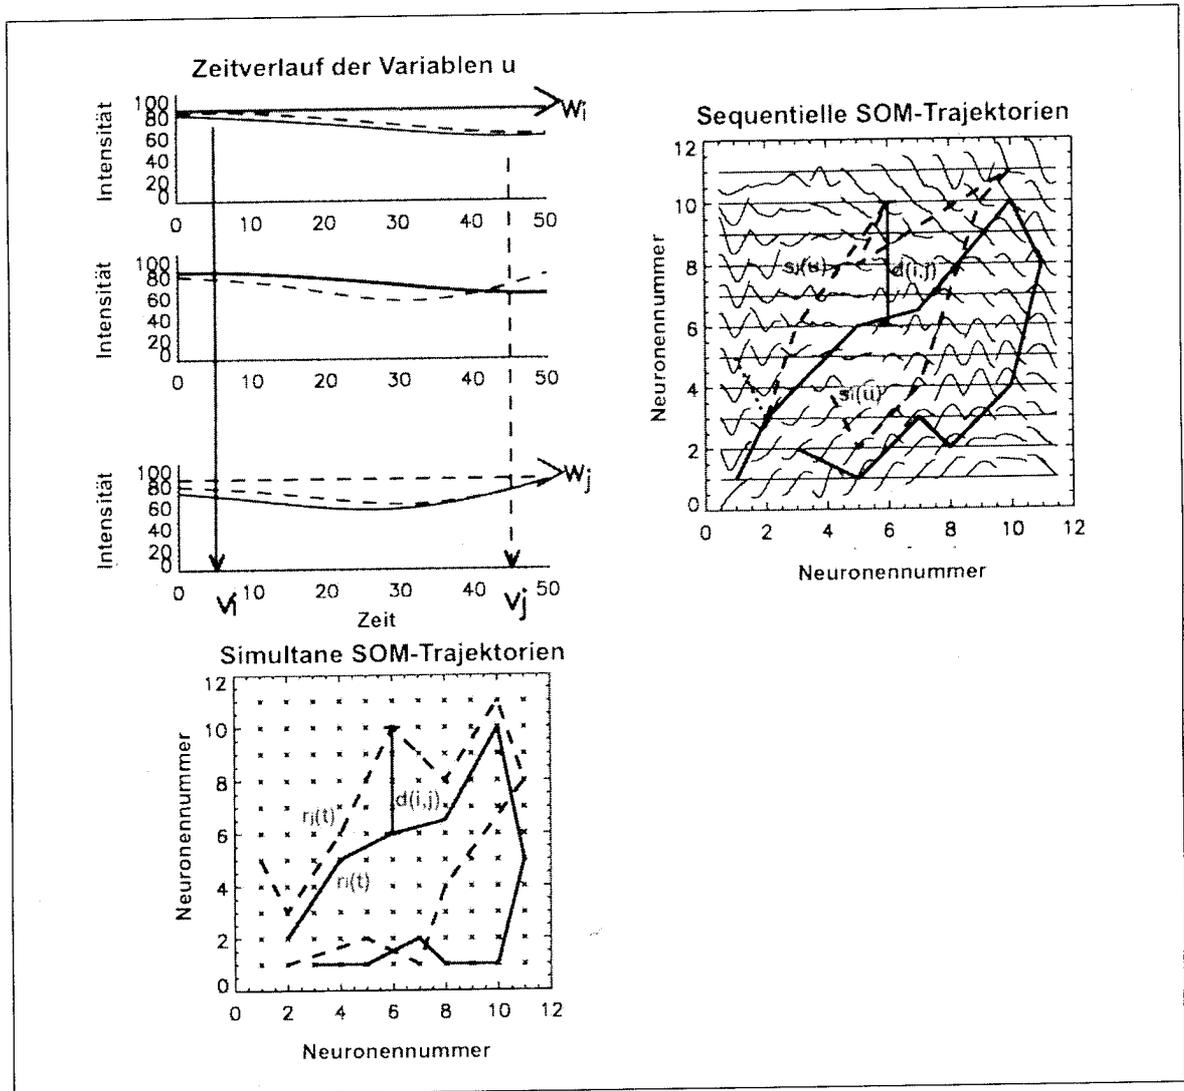


Abb. 1. Schematische Darstellung von zwei unterschiedlichen prozessorientierten Strukturen von Eingangsdaten.

In einem Ansatz (z. B. Bauer & Schöllhorn, 1997) werden die Eingabevektoren $v_i(t)$ bis $v_j(t)$ mittels SOM auf die Trajektorien $r_i(t)$ und $r_j(t)$ in einem niedrigdimensionalen Raum abgebildet. In Abbildung 1 besteht die SOM aus 11x11 Knoten (Neuronen). In dieser SOM repräsentiert jeder Bereich einen Zustand eines Athleten an einem konkreten Zeitpunkt. Die Trajektorie repräsentiert den Zeit-Verlauf der Bewegung des Athleten. In dieser niedrig dimensionalen Karte werden zwei modellierte Bewegungen $r_i(t)$ und $r_j(t)$ typischerweise auf Ähnlichkeit verglichen, indem die Distanz $d(i,j)$ zwischen zwei Trajektorien anhand der Summen aller Distanzen zwischen $r_i(t)$ und $r_j(t)$ berechnet werden. In einem weiteren Schritt wird die Struktur der Distanzen entweder mit Hilfe einer Clusteranalyse (Bauer et al., 1997) analysiert oder die Trajektorien werden als Eingabevektoren für eine weitere SOM (Barton, 1999) verwendet. In beiden Fällen werden die Bewegungstechniken anhand ihrer Ähnlichkeit gruppiert und stellen daher ein Modell für Bewegungstechniken dar.

Beim zweiten Ansatz werden die Eingabevektoren als einzelne Zeitverläufe der Variablen gewählt. Für den Vergleich von zwei Bewegungen werden die Variablen-Zeit-Verläufe $w_i(t)$ und $w_j(t)$ auf die Trajektorien $s_i(u)$ und $s_j(u)$ abgebildet und dann ebenfalls anhand der relativen Distanzen bezüglich ihrer Ähnlichkeit verglichen. Die anschließenden Schritte gleichen dann dem ersten Ansatz.

Interessanterweise bieten beide Ansätze die Möglichkeit, Bewegungsqualitäten quantitativ zu analysieren, die bislang weitestgehend vernachlässigt wurden. Speziell für Lern- und Entwicklungsprozesse, bei denen qualitative Änderungen in den Bewegungstechniken recht häufig auftreten, scheint dieser Ansatz vielversprechend. Dieser Ansatz der Bewegungsmodellierung erlaubt die Klassifikation von a) Bewegungsklassen wie Gehen, Springen, Laufen, Werfen..., b) Modi von Bewegungsklassen wie hüpfendes oder schleichendes Gehen und c) individuelle Stile von Bewegungsklassen und ihren Modi. Ein Transfer auf spielanalytische Fragestellungen bietet die Möglichkeit, auch taktische Verhaltensmuster quantitativ zu untersuchen.

2.2 Analyse von Bewegungstechniken mithilfe von selbstorganisierenden Karten

Die Anwendung von selbstorganisierenden KNN auf der Ebene von Zeitskalen der Bewegungsanalyse untersucht die Entwicklung von zwei Hochleistungsathleten während eines Jahres im Training und im Wettkampf (Bauer & Schöllhorn, 1997). Auch hierzu wurden mithilfe von SOMs 53 Diskuswürfe (45 von einem Zehnkämpfer, 8 von einem Spezialisten) analysiert. Jeder Wurf hatte 34 kinematische Zeitverläufe, die auf 51 Zeitpunkte zeitnormiert wurden. Diese komplexen hochdimensionalen Zeitverläufe wurden auf einen niedrigdimensionalen 11×11 Neuronen großen Ausgaberaum abgebildet. Die Ergebnisse zeigen für einen Athleten einen qualitativen Lernprozess, der durch eine disjunkte Trennung der Versuche vor und nach einer Intervention charakterisiert war. Die Analyse des zweiten Athleten zeigte eine tagesabhängige Wurftechnik.

In einem ähnlichen Untersuchungsansatz wurden 51 Speerwürfe von 37 nationalen und internationalen Weltklasseathletinnen analysiert (Schöllhorn & Bauer, 1998). Eine kleinere Variation innerhalb der Cluster der nationalen Athletinnen im Vergleich zu den internationalen stellt die Existenz einer idealen personenunabhängigen Wurftechnik grundlegend in Frage. Ferner wurden Cluster für männliche und Cluster für weibliche Wurfmuster identifiziert, sowie personenspezifische Wurfmuster, die über mehrere Jahre stabil waren. Während diese Untersuchung bei zwei Athletinnen stabile fingerabdruckähnliche Wurfmuster über mehrere Jahre offenbarte, zeigte die Untersuchung des Gehens mit unterschiedlich hohen Schuhabsätzen eine ähnliche Stabilität der individuellen Gangmuster bis zu einer Absatzhöhe von 5.4 cm (Schöllhorn, Nigg, Stefanyshyn & Liu, 2002).

Die Anwendung ähnlicher SOMs lieferte auch Hinweise für die Individualität von Bewegungsmustern im Allgemeinen und für Laufmuster im Speziellen (Schöllhorn et al., 1995). Bei der Analyse von drei bis fünf Doppelschritten von 20 Läufern während eines 2000 m Laufs, war es nicht nur möglich, automatisch zwischen rechtem Bodenkontakt, Flugphase und linkem Bodenkontakt zu unterscheiden, sondern mit

Hilfe der kinematischen Daten während eines einzelnen Bodenkontakts die Person zu 91 % in der linken Kontaktphase und zu 96 % in der rechten Kontaktphase zu erkennen, jedoch nur zu 75 % während der Flugphase. Offensichtlich kommt es während der Auseinandersetzung mit den größeren Kräften während des Bodenkontakts zu einer stärkeren Offenbarung der individuellen Charakteristiken.

Barton und Mitarbeiter berichten über die Ergebnisse einer Studie, in der sie SOMs mit 12 x 8 Neuronen anwendeten, um den Innenseitstoß von zwei Fußballern im Hinblick auf Distanz und Genauigkeit zu analysieren (Lees, Barton & Kershaw, 2003). Die Ergebnismatrix zeigte Unterschiede zwischen Aufgabe und Spielern. In einem ähnlichen Ansatz modellierten Lees und Barton (2005) mehrere Kickformen von 6 Fußballspielern. Die Ergebnisse konnten, ähnlich zu Schöllhorn et al. (1995), zwischen links- und rechtsdominanten Spielern unterscheiden.

Zeitskalenunabhängige Daten wurden für das Training einer SOM verwendet, um die Kugelstoßbewegung von Schülern zu modellieren (Eimert, 1997). Im Rahmen einer sportunterrichtsrelevanten Fragestellung modellierte Eimert die Beurteilung von Kugelstoßbewegungen auf der Basis von zwei unterschiedlichen Sätzen von Eingangsvariablen. Ein Datensatz bestand aus Schulnoten von 1 (beste) und 6 (schlechteste), und der andere Datensatz beinhaltete ausgewählte zeitdiskrete Körperwinkel, die als wesentlich für die Kugelstoßbewegung erachtet wurden. In beiden Fällen wurden die Daten anhand der gleichen Videos erhoben. Die Sportlehrer evaluierten die Qualität der aufgenommenen Kugelstoßbewegungen anhand vorab vereinbarter Kriterien. Eine analoge Beurteilung fand anhand der ausgewählten kinematischen Merkmale statt. Beide Datensätze wurden anschließend in eine SOM mit 11 x 11 Neuronen gegeben. Die Clusterung bzw. Neuronenaktivierung von beiden Datensätzen wurden miteinander qualitativ verglichen und zeigten recht gute Übereinstimmung. Hier sollte jedoch erwähnt werden, dass aus epistemologischer Sicht dadurch eher weitere Hinweise dafür gefunden wurden, dass KNN-Modelle für diese Fragestellung gut geeignet sind, als dass mit diesem Ansatz die Überlegenheit bestimmter Kugelstoßtechniken gezeigt werden kann.

Der Ansatz der dynamisch kontrollierten Netzwerke (DyCoN; Perl, 2000) erlaubt, den Trainingsprozess an dynamische, sich ständig ändernde Situationen selbst anzupassen. Ein Vorteil der von Perl entwickelten DyCoNs wird daher in ihrer Trainierbarkeit gesehen. Ist eine selbstorganisierte Karte einmal trainiert, kann sie zwar sehr gut interpolieren, liegen jedoch in einer späteren Phase Daten vor, die außerhalb des trainierten Bereichs angesiedelt sind, muss das Netz wieder von neuem trainiert werden. Im Unterschied hierzu kann ein trainiertes DyCoN einfach mit dem neuen Datensatz weiter trainiert werden, ohne von vorne zu beginnen. So können qualitative Lern- und Adaptationsprozesse durch das zugrunde liegende Leistungspotenzial-Metamodell (Mester & Perl, 2000) adäquater simuliert werden (Perl & Baca, 2003). Die Kombination von DyCoNs mit Neuronalen Gasen (Martinez & Schulten, 1991; Martinez & Schulten, 1994; Fritzke, 1995) führte letztendlich zu den so genannten DyCoNG-Modellen.

Schmidt, Fikus und Perl (2008) nutzten das DyCoN zur Erkennung des Expertisegrads anhand kinematischer Bewegungsmuster beim Basketball-Freiwurf. Sowohl individuelle als auch expertiseabhängige Charakteristiken ließen sich identifizieren. Neben der Erkennung von Personen anhand kinematischer oder dynamischer Daten von Bewegungen, die nur 200 ms dauern (Schöllhorn et al., 2002), liefern Ergebnisse von Untersuchungen eines eng benachbarten Forschungsfelds mit einem ähnlichen Modellierungsansatz deutliche Hinweise auf eine Abhängigkeit des Bewegungsmusters vom offerierten Variationsumfang beim Training (Janssen, Beckmann, Gebkenjans & Schöllhorn, 2008). Serielle Übungsausführung führte beim Tennisaufschlag zu größerer Bewegungsvariation als geblockte Ausführung. Zur Analyse wurden hierzu SOMs eingesetzt. Die Abhängigkeit des Gangmusters von emotionalen Zuständen oder sogar von der Musik, die gerade gehört wird (Janssen et al., 2008) deutet auf ein in hohem Maße situatives Bewegungsmuster hin und stellt ein neben dem oben genannten personenübergreifenden Bewegungsmuster auch ein zeitlich überdauerndes Bewegungsmuster grundlegend in Frage (Schöllhorn, Mayer-Kress, Newell & Michelbrink, 2009). In der Konsequenz weisen die Ergebnisse auf eine differenziertere Form der Diagnostik und bilden damit eine individualisiertere Form der Therapie und des Trainings. Insgesamt zeigen die aufgeführten Ansätze einige Möglichkeiten zur Identifizierung von Bewegungscharakteristiken, die im Allgemeinen durch eine Vielfalt an Details in den multiplen Zeitreihen verborgen sind.

2.3 Analyse taktischen Verhaltens in Sportsportarten anhand von SOMs

Der erste Einsatz von Kohonen feature Karten im Bereich der Sportspiele erfolgt erstmals 1999 im Volleyball (Perl & Lames, 2000). In dem Ansatz wurden vollständige Spielzüge modelliert. Ein Spielzug ist hierbei beschrieben mit Hilfe einer Reihenfolge kodierter Spielzustände (=Aktivitäten während des Spiels), wie z. B. Aufschlag – Rückschlag – Abwehr – Angriff – Punkt. Die Klassifikationsergebnisse zeigten deutlich getrennte Cluster und konnten Spielprozesse trennen, die charakteristische Strukturen des Spiels enthielten. Insgesamt 5.000 Prozesse waren notwendig, um das Netz zu trainieren. Durch das Kodieren von Spielzügen anhand von Spielzonen, in denen sich die Spieler beim Schlagen des Squashballs aufhielten, konnte der Ansatz auf die Analyse von Schlägersportarten mittels DyCoN übertragen werden (Perl, 2002). Die Ergebnisse lieferten Hinweise für ein Gegner-spezifisches Verhalten, das relativ stabil war gegen denselben Gegner, sich jedoch grundlegend änderte gegen andere Gegner. Die o. g. DyCoN-Modelle von Jürgen Perl wurden erfolgreich neben vielen anderen Anwendungen außerdem bei der Identifikation von (Taktik-) Mustern im Tischtennis sowie Rudern (Perl & Baca, 2003) eingesetzt. Zur Vermeidung der zeitaufwendigen Kodierung der Spieleraktionen oder Bestimmung entsprechender Spielzonen mit Hilfe eines Spezialisten bzw. Scouts schlägt Schöllhorn (2003) verschiedene quantitative Ansätze zur Analyse von Sportspielen vor, die auf einem Transfer des o. g. Ansatzes zur Bewegungsanalyse auf die Spielanalyse basieren. Hierfür werden die Spieler mittels Video aufgenommen und

ihre Bewegungen auf dem Spielfeld anhand ihrer x- und y-Koordinaten beschrieben. Z. B. werden in einem Volleyballspiel die Bewegungen der Spieler auf 6 (eine Mannschaft) oder 12 (zwei Mannschaften) auf zwei Zeitverläufe ihrer x- und y-Koordinaten abgebildet und als Eingabevektoren für das Training von selbstorganisierenden Karten genutzt, um automatisch mannschaftsspezifisches Verhalten bzw. Spielzüge zu identifizieren (Jäger, Perl, & Schöllhorn, 2007) oder um ein MLP zu trainieren, um Mannschaften anhand ihrer relativen Bewegungen zu erkennen (Jäger, 2006). DyCoNG-Modelle wurden von Perl, Memmert, Bischof und Gerharz (2006) zur Analyse und Klassifikation kreativer Lernverläufe in Spisportarten eingesetzt und auf ihre Fähigkeit überprüft, Lernverläufe zu simulieren und zu optimieren.

3 Schlussbetrachtungen

Aufgrund ihrer Eigenschaften zeigen künstliche neuronale Netze ein breites und vielseitiges Feld von Anwendungsmöglichkeiten in den Sportwissenschaften. Trotz ihrer scheinbar leichten Bedienung ist ein vorsichtiger Umgang und Wissen über die Spezifitäten dieser Art der Modellierung notwendig für einen verantwortungsvollen Umgang und die Interpretation der Ergebnisse. In Anlehnung an Bartlett (2006) werden Kohonen-Karten sich wohl zu Standardwerkzeugen in der Sportbiomechanik und den Bewegungswissenschaften entwickeln, speziell wenn die abgebildeten Technikelemente identifiziert werden können. Dynamisch kontrollierte Netze werden zukünftig vermehrt zur Untersuchung motorischer Lernprozesse eingesetzt werden. Mehrschichtige MLPs werden eine bedeutendere Rolle im Rahmen der Technikanalyse übernehmen. Entsprechend den Anwendungen im Bereich des Gesundheitswesens (Begg et al., 2006), der Gang-Analyse (Schöllhorn et al., 2002), der klinischen Biomechanik (Schöllhorn, 2004) oder anderen Gebieten ist davon auszugehen, dass Anwendungen neuronaler Netze ein enormes Potential im Bereich der Sportwissenschaft aufweisen.

Literatur

- Bartlett, R. (2006). Artificial intelligence in sports biomechanics: new dawn or false hope? *Journal of Sports Science and Medicine*, 5, 474-479.
- Barton, G. (1999). Interpretation of gait data using Kohonen neural networks. *Gait & Posture*, 10 (1), 85-86.
- Bauer, H.-U. & Schöllhorn, W.I. (1997). Self-Organizing Maps for the Analysis of Complex Movement Patterns. *Neural Processing Letters*, 5, 193-199.
- Begg, R.K., Kamruzzaman, J. & Sarker, R. (2006). *Neural Networks in Healthcare*. Hershey: Idea Group Publishing.
- Condon, E.M., Golden, B.L. & Wasil, E.A. (1999). Predicting the success of nations at the Summer Olympics using neural networks. *Computers & Operations Research*, 26, 1243-1265.
- 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.
- Eimert, E. (1997). *Beobachten und Klassifizieren von sportlichen Bewegungen mit neuronalen Netzen*. Dissertation, Universität Tübingen.

- Fritzke, B. (1995). Growing Grid: A self organizing network with constant neighborhood range and adaptation strength. *Neural Processing Letters*, 2, 9-13.
- Herren, R., Sparti, A., Aminian, K. & Schutz, Y. (1999). The prediction of speed and incline in outdoor running in humans using accelerometry. *Medicine and Science in Sports and Exercise*, 31, 1053-1059.
- Horak, M. (1992). The utility of connectionism for motor learning: A Reinterpretation of contextual interference in movement science. *Journal of Motor Behavior*, 24, 58-66.
- Jäger, J.M. (2006). *Mustererkennung im Sportspiel*. Marburg: Tectum.
- Jäger, J., Alichmann, M. & Schöllhorn, W.I. (2003). Erkennung von Ermüdungszuständen anhand von Bodenreaktionskräften mittels neuronaler Netze. In G.-P. Brüggemann & G. Morey-Klapsing (Red.), *Biologische Systeme. Mechanische Eigenschaften und ihre Adaptation bei körperlicher Belastung* (Schriften der Deutschen Vereinigung für Sportwissenschaft, 135, S. 179-183). Hamburg: Czwalina.
- Jäger, J.M., Perl, J. & Schöllhorn, W.I. (2007). Analysis of players' configurations by means of artificial neural networks. *International Journal of Performance Analysis in Sport*, 7, 90-105.
- Janssen, D., Schöllhorn, W.I., Lubienetzki, J., Fölling, K., Kokenge, H. & Davids, K. (2008). Recognition of emotions in gait patterns by means of artificial neural nets. *Journal of Nonverbal Behavior*, 32 (2), 79-92.
- Janssen, D., Beckmann, H., Gebkenjans, F. & Schöllhorn, W.I. (2008). Analysing learning approaches by means of complex movement pattern analysis. In Institute of Sport of the Autonomous Region of Madeira (Ed.), *International Congress of Complex Systems in Sport & 10th European Workshop of Ecological Psychology. Book of abstracts* (S. 64-66). Madeira, Portugal: SREC.
- Jordan, M.I. & Rumelhart, D.E. (1992) Forward models: Supervised learning with a distal teacher. *Cognitive Science*, 16, 307-354.
- Kohonen, T. (2001). *Self-Organizing Maps* (3. ed.). Berlin: Springer.
- Künzell, S. (1996). *Motorik und Konnektionismus. Neuronale Netze als Modell interner Bewegungsrepräsentation*. Köln: bps.
- Lees, A. & Barton, G. (2005). A characterisation of technique in the soccer kick using a Kohonene neural network analysis. In T. Reilly, J. Cabri, & D. Araujo (Eds.), *Science and Football V* (S. 83-88). London UK: Routledge.
- Lees, A., Barton, B. & Kershaw, L. (2003). The use of Kohonen neural network analysis to establish characteristics of techniques in soccer. *Journal of Sports Sciences*, 21, 243-244.
- Maier, K.D. (2001). Neural Network Modelling studied on the example of shot-Put flight. In J. Mester, G. King, H. Strüder, E. Tsolakidis & A. Osterburg. (Eds.), *Profiles and Perspectives. Proceedings of the 6th Annual Congress of the European College of Sport Science* (S. 332). Köln: Sport und Buch Strauß.
- Maier, K.D., Meier, P., Wagner, H. & Blickhan, R. (2000). Neural network modelling in sports biomechanics based on the example of shot-put flight. In Y. Hong & D.P. Johns (Eds.), *Proceedings of XVIII International Symposium on Biomechanics in Sports. Hong Kong* (S. 550-553). Chinese University of Hong Kong: ISBS.
- Maier, K.D., Wank, V. & Bartonietz, K. (1998). Simulation der Flugweite beim Speerwurf durch neuronale Netze. In J. Wiemeyer (Hrsg.), *3. Gemeinsame Tagung der dvs-Sektionen Biomechanik, Sportmotorik und Trainingswissenschaft, 17.-19. September 1998. Abstractband*. Darmstadt: Technische Universität.
- Maier, K.D., Wank, V., Bartonietz, K. & Blickhan, R. (2000). Neural network based models of javelin flight: prediction of flight distances and optimal release parameters. *Sports Engineering*, 3, 57-63.
- Mester, J. & Perl, J. (2000). Grenzen der Anpassungs- und Leistungsfähigkeit aus systemischer Sicht – Zeitreihenanalyse und ein informatisches Metamodell zur Untersuchung physiologischer Adaptationsprozesse. *Leistungssport*, 30 (1), 43-51.
- Perl, J. (2000). Artificial neural networks in Sports: New Concepts and Approaches. *International Journal of Performance Analysis in Sport*, 1, 106-121.
- Perl, J. (2002). Game analysis and control by means of continuously learning networks. *International Journal of Performance Analysis of Sport*, 2, 21-35.
- Perl, J. & Baca, A. (2003). Application of neural networks to analyze performance in sport. In E. Müller, H. Schwameder, G. Zallinger, & F. Fastenbauer (Eds.), *Proceedings 8th Annual Congress of the European College of Sport Science, Salzburg* (S. 342). Salzburg: ECSS.

- Perl, J. & Lames, M. (2000). Identifikation von Ballwechselverlaufstypen mit Neuronalen Netzen am Beispiel Volleyball. In W. Schmidt & A. Knollenberg (Hrsg.), *Sport – Spiel – Forschung: Gestern. Heute. Morgen* (Schriften der Deutschen Vereinigung für Sportwissenschaft, 112, S. 211-215). Hamburg: Czwalina.
- Perl, J., Memmert, D., Bischof, J. & Gerharz, C. (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.
- Ringwood, J.V. (1999). Anaerobic threshold measurement using dynamic neural network models. *Computers in Biology and Medicine*, 29, 259-271.
- Schmidt, A., Fikus, M. & Perl, J. (2009). Typisierung von Basketball-Freiwürfen mit Hilfe Neuronaler Netze. In M. Lames, C. Augste, O. Cordes, C. Dreckmann, K. Görsdorf & M. Siegle (Hrsg.), *Gegenstand und Anwendungsfelder der Sportinformatik* (Schriften der Deutschen Vereinigung für Sportwissenschaft, 189, S. 189-194). Hamburg: Czwalina.
- Schöllhorn, W.I. (2003). Coordination Dynamics and its consequences on Sports. *International Journal of Computer Science in Sport*, 2, 40-46.
- Schöllhorn, W.I. (2004). Applications of artificial neural nets in clinical biomechanics. *Clinical Biomechanics*, 19, 876-898.
- Schöllhorn, W.I. & Bauer, H.-U. (1995). Linear - nonlinear classification of complex time course patterns. In J. Bangsbo, B. Saltin, H. Bonde, Y. Hellsten, B. Ibsen, M. Kjaer, & G. Sjogaard (Eds.), *Conference proceedings of the 2nd European College of Sport Science* (S. 308-309). Copenhagen: University of Copenhagen.
- Schöllhorn, W.I. & Bauer, H.-U. (1998). Identifying individual movement styles in high performance sports by means of self-organizing Kohonen maps. In H.J. Riehle & M. Vieten (Eds.), *Proceedings of the XVI ISBS 1998* (S. 574-577). Konstanz: University Press.
- Schöllhorn, W.I., Jäger, J.M. & Janssen, D. (2008). Artificial neural network models of sports motions. In Y.B. Hong & R. Bartlett (Eds.), *Routledge Handbook of Biomechanics and Human Movement Science* (S. 50-64). London: Routledge.
- Schöllhorn, W.I., Mayer-Kress, G., Newell, K.M. & Michelbrink, M. (2009). Time scales of adaptive behavior and motor learning in the presence of stochastic perturbations. *Human Movement Science*, 28 (3), 319-333.
- Schöllhorn, W.I., Nigg, B.M., Stefanyshyn, D. & Liu, W. (2002). Identification of individual walking patterns using time discrete and time continuous data sets. *Gait & Posture*, 15, 180-186.
- Schöllhorn, W.I. & Perl, J. (2002). Prozessanalysen im Sport. *Spectrum der Sportwissenschaften*, 14, 30-52.
- Stachowiak, H. (1973). *Allgemeine Modelltheorie*. Wien: Springer.
- Väinämö, K., Mäkikallio, T., Tulppo, M. & Rönning, J. (1998). A Neuro-Fuzzy approach to aerobic fitness classification: a multistructure solution to the context sensitive feature selection problem. *Proceedings of the International Neural Network ICNN, Anchorage, Alaska, USA, 1998 May 4-9*. (pp. 797-802).
- Väinämö, K., Nissila, S., Mäkikallio, T., Tulppo, M. & Rönning, J. (1996). Artificial neural networks for aerobic fitness approximation. *International Conference on Neural Networks (ICNN '96), USA (1996)* (S. 1939-1949).
- Yan, B. & Li, M. (2000). Shot Put Technique Analysis using ANN AMT Model. In Y. Hong & D. Johns (Eds.), *Proceedings of the XVIII. International Symposium on Biomechanics in Sports, Volume 2* (S. 580-584). Hong Kong SAR: The Chinese University of Hong Kong.
- Yan, B. & Wu, X. (2000). The ANN-based analysis model of the sport Techniques. In Y. Hong & D. Johns (Eds.), *Proceedings of the XVIII. International Symposium on Biomechanics in Sports, Volume 2* (S. 585-589). Hong Kong SAR: The Chinese University of Hong Kong.
- Zell, A. (1996). *Simulation Neuronaler Netze*. Bonn, Reading, Mass.: Addison Wesley.