

99 / ZX 7030 Q1

Anwendungen der Fuzzy-Logik und Neuronaler Systeme

UB Augsburg

<08031527560017

<08031527560017



Karl Quade (Redaktion)

Neuronale Netzwerke:

Modelle für kognitive Prozesse der Bewegungsproduktion?

Stefan Künzell

Zusammenfassung

In diesem Beitrag wird der Frage nachgegangen, ob neuronale Netzwerke adäquate Modelle für die kognitiven Prozesse bei der Kontrolle und dem Erlernen von sportlichen Bewegungen sein können. Dazu werden zunächst die allgemeinen Eigenschaften neuronaler Netzwerke im Hinblick auf ihren Modellcharakter beleuchtet, danach wird JORDANS (1989) Netzwerk-Architektur als Beispiel für die konnektionistische Modellierung von Bewegungslernen vorgestellt. Darauf aufbauend wird mit einer von KÜNZELL 1994 entwickelten Vereinfachung dieses Netzes das Erlernen des Basketball-Positionswurfs simuliert, dabei wird die Wirksamkeit des Kontextinterferenz-Effekts beim Lernen im Netz überprüft sowie ein Lösungsweg für das Problem der Freiheitsgrade gezeigt. Abschließend wird die Relevanz konnektionistischer Modellierung kognitiver Prozesse für die sportwissenschaftliche Theoriebildung und die sportliche Praxis diskutiert.

Neuronale Netzwerke und ihre Eigenschaften

Neuronale Netzwerke werden in der Wissenschaft unter zwei Gesichtspunkten behandelt: Zum einen als mächtige Werkzeuge zur Modellierung nichtlinearer Zusammenhänge, zum anderen als Modell zur Exploration der Mikrostruktur der Kognition¹. Der erstgenannte Ansatz kommt in der Sportwissenschaft hauptsächlich in der biomechanischen Modellbildung zur Anwendung – dies ist Thema der Beiträge von EIMERT, FARKAS und ANDREAS in diesem Band. Der zweitgenannte Ansatz – also die Frage, inwieweit neuronale Netzwerke in der Lage sind, kognitive Prozesse mit dem Anspruch psychologischer Realität abzubilden – soll im Mittelpunkt der folgenden Ausführungen stehen.

Die beiden Bände über *Parallel Distributed Processing* von RUMELHART/MCCLELLAND u.a. bzw. MCCLELLAND/RUMELHART u.a. (1986) führten in den USA zu einer regen Forschungstätigkeit an der Schnittstelle zwischen Informatik, den „Neurowissenschaften“ und der Psychologie, und bald wurde dieser neue Ansatz unter dem Namen „Konnektionismus“ (*connectionism*) eine ernsthafte Herausforderung für das vorherrschende klassische Informationsverarbeitungsparadigma (vgl. z. B. SCHNEIDER 1987).

Neuronale Netzwerke bestehen aus mehreren miteinander verbundenen Berechnungseinheiten, welche abstrakte mathematische Modelle biologischer Neuronen sind. Sie werden daher auch in künstlichen, auf Rechnern emulierten Netzen „Neuronen“ genannt. Vereinfacht beschrieben vergleichen sie die Summe der bahrenden und hemmenden Erregungen mit einem Schwellenwert. Ist die Erregung größer als der Schwellenwert, „feuern“ die Neuronen, andernfalls feuern sie nicht. Beachtenswert dabei ist, daß in der Regel nur *lokal* verfügbare Informationen benutzt werden. Es gibt also keine Zustände höherer Ordnung, die die Funktion eines Neurons beein-

flussen, sie ist gleichfalls unabhängig von den Aktivitäten anderer, nicht mit dem betrachteten Neuron verbundenen Neuronen.² Diese Merkmale geben konnektionistischen Modellen eine gewisse neurophysiologische Plausibilität; dabei darf aber nicht übersehen werden, daß künstliche neuronale Netzwerke nicht annähernd die komplexen Strukturen eines Gehirns abbilden können!

Obwohl die einzelnen Neuronen also nur lokale Information verarbeiten, entstehen durch ihr paralleles Zusammenwirken *globale* Eigenschaften des gesamten Netzes, die für eine Modellierung kognitiver Prozesse hochinteressant sind:

Neuronale Netze speichern assoziativ, die Struktur des Eingabevektors bewirkt die Assoziation mit einem Ausgabevektor. Ähnliche Eingabevektoren werden mit ähnlichen oder gleichen Ausgabevektoren assoziiert. Wenn beispielsweise bei der Erkennung von sportlichen Bewegungsmustern wie ein Doppelsalto im Gegensatz zu dem trainierten Muster dieses vom Sprungturm in der Schwimmhalle ausgeführt wird, kann das Netz dennoch den zu dem Salto gehörenden Ausgabevektor liefern. Aus demselben Grund sind Netze tolerant gegenüber zufälligen Eingabeschwankungen (*noise*). Verrauschte Eingaben sind aber bei menschlicher Wahrnehmung eher die Regel als die Ausnahme.

Neuronale Netze repräsentieren emergent. Zwar ist das Wissen des Netzes in den Verbindungen zwischen den Neuronen codiert, aber einer Repräsentation entspricht erst das Aktivierungsmuster, das im Zusammenspiel von Eingabevektor und den gewichteten Verbindungen zwischen den Neuronen als parallel verteilter Prozeß entsteht. Ihre Bedeutung ist nicht durch eine semantische Auswertung festgelegt, sondern entsteht erst in Interaktion mit der Umwelt (vgl. SCHEERER 1993, 158-159). Auch beim Menschen ist die Bedeutung eines wahrgenommenen Gegenstands situationsabhängig: So kann ein Holzklotz je nach individueller Befindlichkeit als Sitzgelegenheit, als Trimm-Dich-Gerät oder als Heizmaterial wahrgenommen werden.

Neuronale Netze können lernen, indem die Stärke der Verbindungen (die „Gewichte“) zwischen den einzelnen Neuronen verändert wird (vgl. hierzu auch den Beitrag von EIMERT in diesem Band). Die Vorschrift zur Modifikation der Gewichte (der „Lernalgorithmus“) kann vom zurückgemeldeten Fehler abhängig sein („überwachtes Lernen“) oder die Eigenschaften des Erregungsmusters selbst verwenden („selbstorganisiertes Lernen“). Eine Variante des letzteren Verfahrens, die in neuronalen Netzwerken häufig Verwendung findet, wurde schon 1949 von HEBB für das menschliche Lernen postuliert. Vereinfacht besagt sie, daß das Gewicht zwischen Neuron A und B bei gleichzeitiger Erregung der Neuronen erhöht, bei unterschiedlicher Erregung erniedrigt werden muß.

Neuronalen Netzen gelingen bestimmte Aufgaben, die der Mensch leicht ausführen kann, wie das Wahrnehmen von Gesichtern oder im allgemeinen von Mustern, auch recht gut. Sie können, im Gegensatz zu regelbasierten Computermodellen, zwischen Bäumen und Telegrafmasten (bzw. zwischen deren digitalisierten Abbildern) unterscheiden. Formale logische Operationen fallen ihnen aber recht schwer, was, wie jeder Mathematiklehrer bestätigen wird, durchaus seine Analogie im menschlichen Verhalten hat.

Neuronale Netze sind robust gegenüber dem Ausfall von einzelnen Neuronen. Sie „stürzen würdevoll ab“, was bedeutet, daß kein totaler Zusammenbruch des Netzwerks bei Ausfall einzelner Neuronen stattfindet. Vom Menschen wissen wir, daß glücklicherweise das Absterben einzelner Neuronen, wie beispielsweise nach Alkoholkonsum, nicht den totalen Zusammenbruch der ko-

Neuronale Netze sind robust gegenüber dem Ausfall von einzelnen Neuronen. Sie „stürzen würdevoll ab“, was bedeutet, daß kein totaler Zusammenbruch des Netzwerks bei Ausfall einzelner Neuronen stattfindet. Vom Menschen wissen wir, daß glücklicherweise das Absterben einzelner Neuronen, wie beispielsweise nach Alkoholkonsum, nicht den totalen Zusammenbruch der kognitiven Leistungen nach sich zieht (trotzdem wird jedoch beim Menschen in Zusammenhang mit diesem Beispiel nur höchst selten von einem „würdevollen“ Absturz gesprochen).

JORDANS Netzwerk zum Bewegungslernen

Die Domäne der neuronalen Netze ist die Modellierung von nicht verbal codiertem Wissen und seiner Anwendung, beispielsweise im Bereich der Wahrnehmung und der Motorik (vgl. RUTKOWSKA 1992; PARKS u.a. 1991). Dabei beschäftigt sich der überwiegende Teil der Forschungsarbeiten mit der Modellierung von Wahrnehmungsprozessen; gerade in jüngster Zeit sind jedoch auch einige vielversprechende Ansätze zur Motorikforschung zu verzeichnen (z. B. BULLOCK/GROSSBERG 1988, 1991; GAUDIANO/GROSSBERG 1992; JORDAN 1989; JORDAN/RUMELHART 1992; KAWATO u.a. 1990; HIRAYAMA u.a. 1993; MORASSO/SANGUINETTI 1992; für einen Überblick vgl. Künzell 1994). Ein aus sportwissenschaftlicher Sicht besonders interessantes Modell präsentiert Jordan, der, teilweise in Zusammenarbeit mit Rumelhart, ein feedforward-Netzwerk zur Steuerung und zum Lernen von Bewegungen entwickelte.

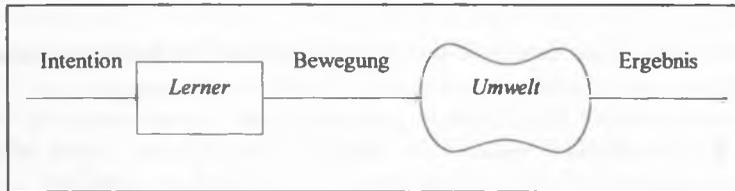


Abb. 1: Beziehung zwischen Lerner und Umwelt (nach JORDAN/RUMELHART 1992, 315).

Ausgangspunkt seiner Überlegungen ist die Idee, daß bei einer erfolgreichen Bewegung die Abbildung von der Intention auf die Bewegung (bzw. die zu ihr führende Muskelinnervation) die Inverse der Abbildung von Bewegung zum Bewegungsergebnis ist (s. Abb. 1), da im erfolgreichen Fall die Intention mit dem Bewegungsergebnis übereinstimmt³.

Zum Erlernen einer Bewegung muß daher (bis zu einem gewissen Grad) zunächst ein *forward model* (s. Abb. 2) erworben werden, das die Umweltfunktion abschätzt, also die „Bewegungsvorstellung“ modelliert. Es wird im folgenden *Bewegungsvorstellungnetz* genannt. Für elementare Bewegungen geschieht dies in den ersten Lebensjahren durch Strampelbewegungen (*motor babbling*). Dabei wird die Abbildung zwischen „zufällig“ erzeugten Muskelinnervationen bei gegebenen Anfangsbedingungen und tatsächlich beobachteten Ergebnissen erlernt. Erst in einem weiteren Schritt kann das *inverse model* erworben werden, das die Funktion erfüllt, aus Intentionen und den wahrgenommenen Anfangsbedingungen Muskelinnervationen zu produzieren. Es soll hier *Bewegungssteuerungsnetz* heißen. Die Intention wird als Vektor in die

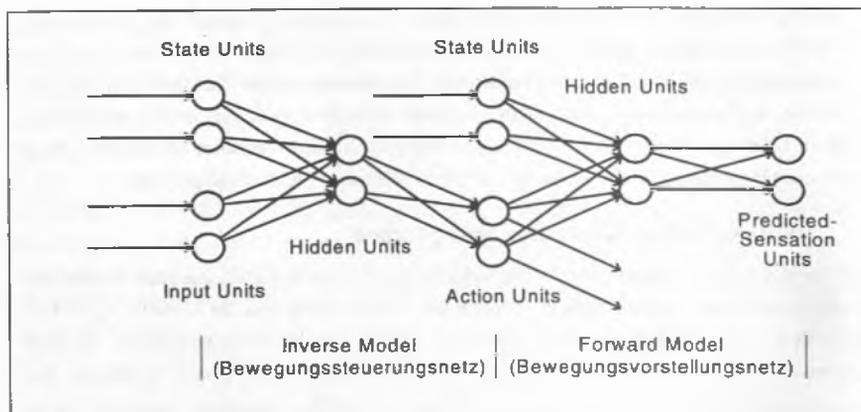


Abb. 2: Vorwärtsgerichtetes Netz (nach JORDAN/RUMELHART 1992, 321). Es besteht aus einem linken Teilnetz, dem *inverse model*, und einem rechten Teilnetz, dem *forward model*. Die *input units* werden durch Vektoren, die die Intention darstellen, erregt, die *state units* durch Vektoren des Zustands der Umwelt. Die *action units* stellen Muskelinnervationen dar und sind die eigentlichen Ausgabevektoren des Netzes, die *predicted-sensation units* sind die Ausgabe des Bewegungsvorstellungsnetzes. *Hidden units* sind die Neuronen der versteckten Schicht.

input units eingegeben, die Anfangsbedingungen in den *state units*. Das Bewegungssteuerungsnetz erzeugt mit dieser Eingabe die Bewegungs- bzw. Muskelinnervationsparameter, sie sind die Ausgabe der *action units*. Das beobachtete Bewegungsergebnis, also der tatsächliche Fehler, wird mit dem Bewegungsziel verglichen. Die wahrgenommene Differenz zwischen tatsächlichem und gewünschtem Ziel wird durch das Bewegungsvorstellungsnetz zurückgeführt. Dies ist möglich, da die Ausgabe des Bewegungsvorstellungsnetzes die Dimension des intendierten Bewegungsziels hat – sie sind sozusagen „in derselben Sprache“ formuliert – und so mit dem Bewegungsergebnis verglichen werden kann. Ist das Bewegungsvorstellungsnetz perfekt gelernt, wird in diesem Schritt der jeweilige Anteil der einzelnen Parameter an dem Fehler ermittelt. Es spielt also die Rolle eines „distalen Lehrers“ (JORDAN/RUMELHART 1992), der den Fehler auf der Beobachtungsebene in einen Fehler auf der Innervationsebene überführt. In einem zweiten Schritt werden diese Fehleranteile zur Korrektur der Gewichte des Bewegungssteuerungsnetzes genutzt. Auch bei nicht perfekt gelerntem Bewegungsvorstellungsnetz wird der beobachtete Fehler, wenn auch langsamer, minimiert.

Zu diesem Verfahren sind noch zwei Alternativen denkbar. Zum einen könnte der zurückgemeldete Fehler aus der Differenz zwischen der Ausgabe des Bewegungsvorstellungsnetzes und der Intention berechnet werden – dazu muß die Bewegung selbst nicht ausgeführt werden, es entspräche dem mentalen Training. Dabei hängt der Lernerfolg entscheidend von der Güte des Bewegungsvorstellungsnetzes ab. Als zweite Möglichkeit liefert die Differenz aus dem tatsächlichen Bewegungsergebnis und der Ausgabe des Bewegungsvorstellungsnetzes den Vorhersagefehler, der zur Korrektur der Bewegungsvorstellung dient.

Ein Netzwerk zum Erlernen des Basketball-Positionswurfs

Eine von KÜNZELL 1994 entwickelte Vereinfachung von JORDANS Netz soll nun verwendet werden, um das Erlernen eines Basketball-Positionswurfs zu simulieren. Diese Bewegung eignet sich besonders, da erstens zur Vereinfachung auf das Modellieren variabler Umweltbedingungen (und damit auf die *state units*) verzichtet und zweitens eine einfache, der Biomechanik entlehnte Bewegungsfunktion, die des schiefen Wurfs, zugrunde gelegt werden kann. Dabei wird die Allgemeinheit des Modells nicht eingeschränkt, denn es ist beweisbar, daß jede stetige Funktion mit neuronalen Netzen beliebig genau approximierbar ist (ROJAS 1993). Es ist also nur ein quantitativer Unterschied, ob lediglich eine einfache biomechanische Funktion oder aber die sehr komplexe Abbildung von Muskelinnervationsvektoren auf Bewegungsergebnisse modelliert wird. Drittens legt natürlich auch die Namensverwandtschaft zwischen dem am Massachusetts Institute of Technology tätigen Michael Jordan und seinem im Sport ungleich bekannteren Namensvetter aus der National Basketball Association diese Wahl nahe.

Zur Lernphase

Als Simulationsaufgabe wurde der Positionswurf im Basketball für eine Korbfenfernung von 3, 5, 7 und 9 m bei einer konstanten Höhendifferenz vom Abflugpunkt zum Korb gestellt. Die vom Netz zu findenden Parameter waren die Abfluggeschwindigkeit v_0 und der Abflugwinkel α . Wie bei vorwärtsgerichteten Netzen üblich, wurde der *backpropagation*-Lernalgorithmus verwendet. Zunächst wurde das Bewegungsvorstellungnetz mit 500 zufällig ausgewählten Winkel/Geschwindigkeits-Kombinationen gelernt. Dem Netz wurde der Unterschied zwischen der (nach der Formel des schiefen Wurfs berechneten) tatsächlichen Weite und der Ausgabe der *predicted-sensation unit* als Fehler zurückgemeldet. Nach 2000 Iterationen wurde das Training abgebrochen. In einem Transferfertest mit 100 neu ermittelten Eingabevektoren ergab sich ein mittlerer Fehler von 7 cm ($s = 7$ cm). Beim nachfolgenden Training des Bewegungssteuerungsnetzes sollte das Netz in der oben erläuterten Weise die Abbildung von einer vorgegebenen Zielweite auf die korrekten Bewegungsparameter α und v_0 lernen.

Zum Kontextinterferenz-Effekt

Der Kontextinterferenz-Effekt besagt, daß bei höherer Interferenz im Übungskontext die Leistung während des Lernens zwar schlechter, in einem anschließenden Retentions- und Transferfertest aber besser ist als bei Übungsbedingungen mit geringerer Kontextinterferenz. Er wurde für den Bereich der Motorik nachgewiesen, indem die Kontextinterferenz durch den Wechsel der Übungsaufgaben herbeigeführt wurde (z. B. SHEA/MORGAN 1979).

Tab. 1: Übersicht über die Übungsbedingungen für die verschiedenen Gruppen von neuronalen Netzen

Gruppe	1	2	3	4	5	6
Anzahl der Blöcke	-	800	400	160	80	4
Anzahl der Wiederholungen pro Block	-	1	2	5	10	200
Reihenfolge	zufällig	3-5-7-9	3-5-7-9	3-5-7-9	3-5-7-9	3-5-7-9
Summe der Trainingsvektoren	800	800	800	800	800	800

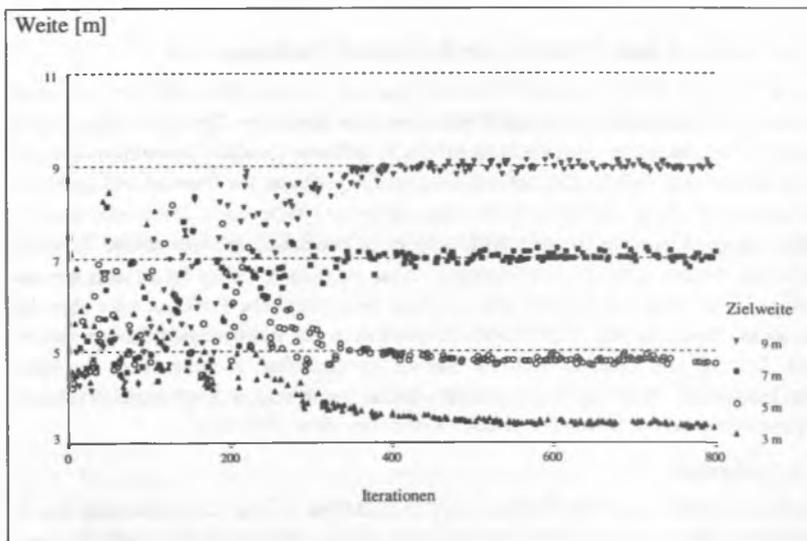


Abb. 3a: Lernverlauf bei zufälliger Wahl der Zielweite (Gruppe 1)

Eine Simulation des Kontextinterferenz-Effekts unter Verwendung der im vorangegangenen Abschnitt vorgestellten Netzwerk-Architektur gelang durch die Anwendung eines unterschiedlichen Treatments für sechs Gruppen von je 20 neuronalen Netzen, die in insgesamt 800 Iterationen unter verschiedenen Kontextbedingungen trainiert wurden (s. Tabelle 1). Die Dynamik des

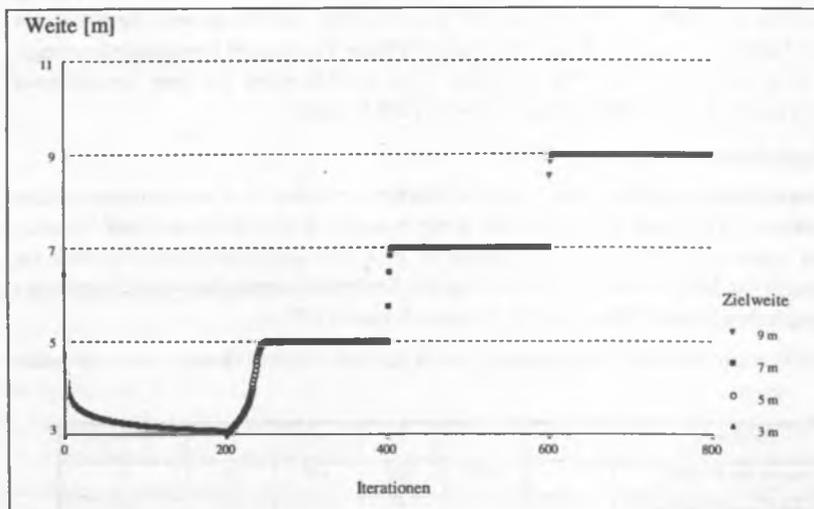


Abb. 3b: Lernverlauf mit 4 Blöcken à 200 Versuchen pro Zielweite (Gruppe 6)

Lernverlaufs wird in den Abbildungen 3a und 3b beispielhaft an den „Extremgruppen“ 1 und 6 verdeutlicht.

Auch die Gruppen 2 bis 5 lernten, die korrekten Bewegungsparameter zu finden. Dabei stellte

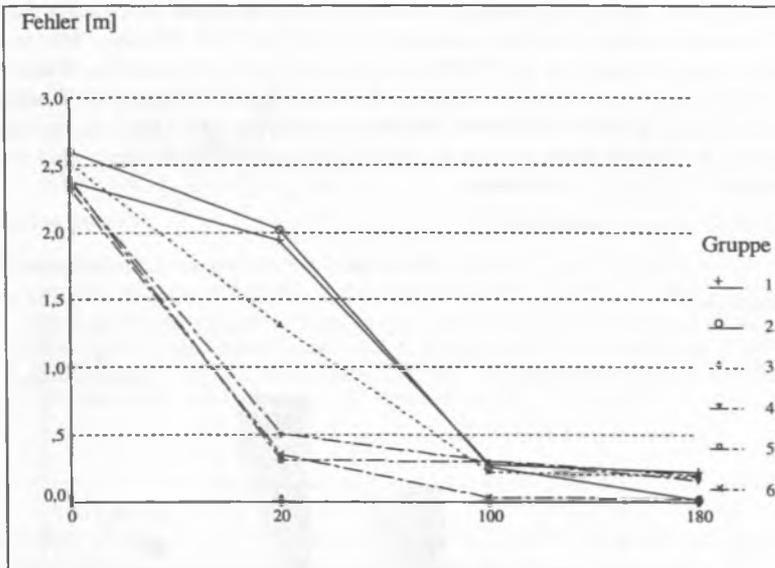


Abb. 4: Lernverlaufsleistung zu Anfang, nach 20, 100 und 180 Iterationen für die einzelnen Gruppen. Dargestellt ist jeweils der Mittelwert des Fehlers über die vier Zielweiten

sich innerhalb eines Blocks recht schnell ein Lernerfolg ein, vor allem bei 5 und 10maliger Wiederholung derselben Zielweite in einem Block (Gruppen 4 und 5), entsprechend länger dauerte aber das richtige Produzieren der Zielweite nach einem Wechsel des Trainingsblocks (eine graphische Darstellung des Lernverlaufs für jede Treatment-Bedingung findet sich in KÜNZEL 1994).

Die Lernverlaufsleistungen wurden zu Beginn des Trainings und nach 20, 100 und 180 Iterationen für jede Zielleistung gemessen. Eine statistische Analyse der in Abb. 4 graphisch veranschaulichten Ergebnisse zeigte eine signifikante Interaktion zwischen dem Gruppen- und dem Meßwiederholungsfaktor ($F_{(15, 342)} = 54,24$; $p < 0,001$). Post-hoc Einzelvergleiche (Scheffé-Test) ließen diese Unterschiede bezüglich des Lernverlaufs im Anfangstest bzw. in der 1. und 2. Meßwiederholung auf drei homogene Untergruppen zurückführen: Eine Untergruppe aus Netzen der Gruppe 1 und 2, eine aus Netzen der Gruppe 3 und eine dritte aus Netzen der Gruppe 4 bis 6. Die in Abb. 4 dargestellten Mittelwerte zeigen dabei, daß höhere Kontextinterferenz in der Trainingsphase ein langsames Lernen zur Folge hat.

In einem Endtest, in dem ein einmaliges Erreichen jeder der vier Zielweiten gefordert wurde, produzierte die Gruppe 6 das jeweils gewünschte Ziel am schlechtesten, die Gruppe 5 am zweit-schlechtesten. Zwischen den Gruppen 1 - 4 ließen sich nach Scheffé-Test keine statistisch bedeutsamen Unterschiede nachweisen ($F_{(5, 114)} = 1608,37$; $p < 0,001$). Dieses Ergebnis bestätigte

sich im Transfertest für die Weiten 4, 6 und 10 m ($F_{(5, 114)} = 1601,32$; $p < 0,001$). Für die Lernphase war also der Kontextinterferenz-Effekt der Vorhersage entsprechend nachzuweisen.

Bei der in Abb. 5 dargestellten Aufschlüsselung der Daten für die einzelnen Zielweiten offenbart sich ein Grund für die hohe Signifikanz im Endtest: Die Netze der Gruppe 6 reproduzieren für jede geforderte Zielweite konstant die im letzten Block 200mal trainierte Zielweite von 9 m. Die Parameter für andere Zielweiten wurden offensichtlich durch das 200malige Wiederholen von 9 m völlig „vergessen“. In der Tendenz zeigte sich dieses Ergebnis auch bei Gruppe 5, während die Gruppen 1 bis 4 anscheinend alle vier Zielweiten „behalten“ haben. Der Transfertest zeigt ein analoges Ergebnis, was beweist, daß Netze der Gruppen 1 bis 4 nicht die vier Zielweiten „auswendig“ gelernt haben, sondern die gesamte Bewegungsfunktion – sogar noch über das Trainingsintervall hinaus – beherrschen.

Zum Problem der Freiheitsgrade

Bei der Produktion der Wurfweite besitzt das Bewegungssteuerungsnetz einen Freiheitsgrad. Es

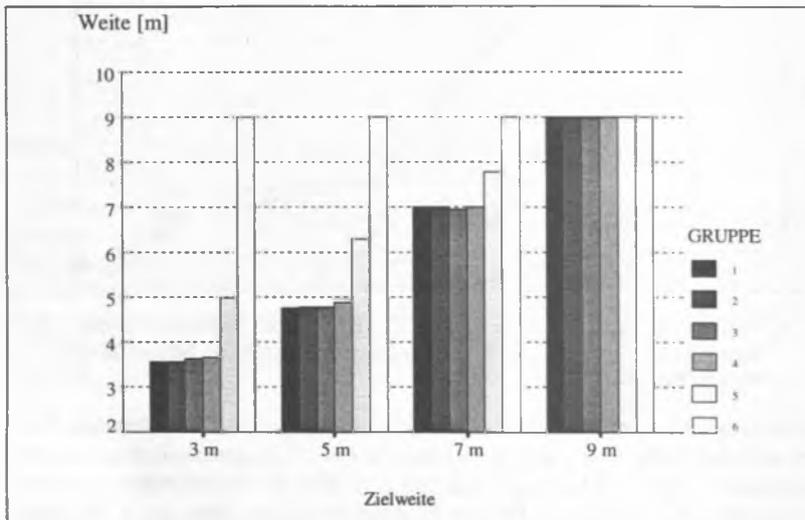


Abb. 5: Aufschlüsselung der erreichten Weiten für die jeweils angestrebte Zielweite nach Gruppen.

gibt unendlich viele α/v_0 -Kombinationen, um die Zielweite zu erreichen; erst bei der Vorgabe einer Randbedingung ist dieser Freiheitsgrad festgelegt. JORDAN unterscheidet in diesem Zusammenhang in seinem Modell zwischen *task-constraints*, also Randbedingungen, die sich aus der Bewegungsaufgabe ergeben, und *intrinsic constraints*, d. h. durch die Eigenschaften des Bewegers festgelegte Randbedingungen, wie beispielsweise die Eigenheiten der Gelenkdynamik, die „Bequemlichkeit“ der Endposition nach diskreten Bewegungen usw. In dieser Simulation wurde eine realitätsnahe aufgabenbezogene Randbedingung formuliert, die darin bestand, die Abfluggeschwindigkeit des Balls zu minimieren. Dazu wurde in einem neuen Bewegungsvorstellungsnetz neben dem Ausgabeneuron für die geschätzte Flugweite ein zweites Neuron auf die geschätzte Abfluggeschwindigkeit trainiert, die Abfluggeschwindigkeit wurde sozusagen als Teil der Bewegungsvorstellung hinzugenommen. Beim anschließenden Training des Bewegungssteuerungsnetzes wurde nicht nur der Fehler der Weite zurückgemeldet, sondern auch ein

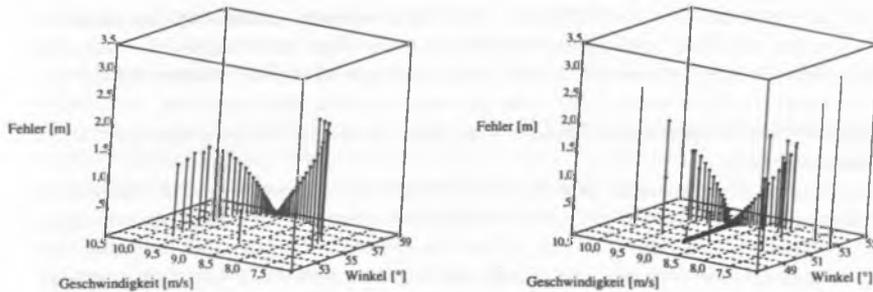


Abb. 6.: Die Abbildung zeigt den Fehler (Länge der Striche, Zielweite 7 m) für die jeweils bei der Iteration gewählten Parameter. Links ist der Lernverlauf ohne Randbedingung dargestellt (das Netz erreicht die Zielweite mit einem Abflugwinkel von $58,4^\circ$ und einer Abfluggeschwindigkeit von $9,2\text{ m/s}$) rechts soll die Abfluggeschwindigkeit minimiert werden (gelernter Abflugwinkel $49,1^\circ$, Abfluggeschwindigkeit $8,9\text{ m/s}$).

Geschwindigkeitsfehler, der stets zurückmeldete, daß die korrekte Geschwindigkeit ein wenig unter der jeweils vom Netz produzierten lag. Dies bewirkte, daß das Netz die Bewegungsgeschwindigkeit sukzessive verminderte. Dabei mußte die Differenz zwischen den Geschwindigkeitsvektoren im Vergleich zu dem rückgemeldeten Fehler der Wurfweite sehr klein sein, da das Netz anderenfalls die Geschwindigkeit minimiert hätte, ohne den Korb zu treffen.

Hierbei zeigte sich, daß das Netz zuerst lernte, die Weite richtig einzustellen und danach die Randbedingung optimierte (Abb. 6). Im Vergleich zum Training ohne Randbedingungen war aber eine erheblich größere Anzahl an Iterationen notwendig, um ein befriedigendes Ergebnis zu erreichen.

Diskussion und Ausblick

In der hier vorgestellten Simulationsstudie wurde versucht, die von JORDAN entworfene Netzarchitektur auf eine Aufgabe aus der Sportpraxis anzuwenden. Es handelte sich hierbei um einen ersten Versuch, kognitive Prozesse mit sportlicher Relevanz zu simulieren. Dabei ist anzumerken, daß das vorgestellte Basketball-Modell aus dem Blickwinkel der Praxis noch offensichtliche Schwächen aufweist. So wird eine Zielweite von 3 m schlechter erlernt als eine Weite von 9 m. Auch das völlige „Vergessen“ von bereits gelernten Würfeln ist praktisch nicht plausibel. Der erstgenannte Makel des Modells ist darauf zurückzuführen, daß keine stochastischen Zusammenhänge in das Modell integriert wurden. Bei der menschlichen Bewegungsproduktion werden sich immer „zufällige“ Schwankungen ergeben, die für einen Wurf über 9 m größer sind als bei einem Wurf über 3 m. Die Berechnung des schiefen Wurfs nach einer Formel ist jedoch für 3 m genau so leicht wie für 9 m. Die trotzdem gefundenen Unterschiede, nämlich das schlechtere Abschneiden bei der Zielweite von 3 m, erklären sich aus Fehlern des Bewegungsvorstellungnetzes. Diese Mängel können relativ leicht behoben werden. Ein von der Bewegungsgeschwindigkeit abhängiger stochastischer Fehler ist einfach zu modellieren, das Bewe-

gungsvorstellungnetz kann verbessert werden, indem der Eingabebereich erweitert und die Zahl der Iterationen erhöht wird.

Der letztere Modellfehler – das „Vergessen“ – liegt darin begründet, daß das Netz als *tabula rasa* mit dem Erlernen des Basketballwurfs begonnen hat und somit über keinerlei „Bewegungsvorerfahrung“ verfügte. Es hatte sozusagen noch nicht gelernt, daß es stärker werfen muß, wenn es weiter werfen „will“. Hier gilt anscheinend für neuronale Netze, was auch im Anfängertraining im Sport für gut befunden wird: Es ist ratsam, vielfältige Bewegungserfahrungen zu ermöglichen.

Eine praktische Stärke konnektionistischer Modellbildung ist aber zweifellos, daß eine Simulation überhaupt möglich ist. Die gelungene Modellierung verschafft dem Modell darüber hinaus eine erhebliche Relevanz mit Blick auf die bewegungswissenschaftliche *Theoriebildung*. Der Wahrnehmungsprozeß wird in einem neuronalen Netz modelliert durch die Aufnahme eines Vektors aus der Umgebung über die Eingabeneuronen und seine Weiterleitung an Neuronen anderer Schichten. Es findet keine Verrechnung der Eingabe statt, die die Neuronen erregenden Reize in bedeutungsvolle Information oder Bewegungen verwandelt, sondern eine Bewegung entsteht direkt durch die Interaktion der Erregungen mit den gelernten Gewichten der Synapsen. Dies kommt der in der *action theory* formulierten Idee der Einheit von Wahrnehmung und Bewegung nahe (z.B. GIBSON 1982; TURVEY 1977). Psychoökologische Gedanken können somit zwanglos in neuronalen Netzwerken wiedergefunden werden.

Gleichzeitig bricht der Konnektionismus aber keineswegs mit der Idee zentraler Repräsentationen. Die generalisierten motorischen Programme und motorischen Schemata von SCHMIDT (1975, 1988) werden durchaus in dem vorliegenden Netz abgebildet, wobei das Bewegungssteuerungsnetz dem *recall schema*, das Bewegungsvorstellungnetz dem *recognition schema* entspricht. Das Netz repräsentiert dabei nicht allein die Schemata, sondern gleichzeitig auch die assoziierten motorischen Programme. Die Unterschiede zwischen Programm und Parameter werden somit eher zu quantitativen denn zu qualitativen.

Welche praktischen Konsequenzen sind nun durch einen paradigmatischen Wechsel in der bewegungswissenschaftlichen Theoriebildung zu erwarten? Hier sind zunächst zwei Vorbemerkungen angebracht:

Gerade im Bereich der motorischen Lerntheorien stehen sehr spezifische, aus Gründen der internen Validität hoch ausdifferenzierte Theorien einer sehr komplexen Sportpraxis gegenüber. Dieser weite Weg „zwischen Elfenbeinturm und Sportplatz“ (HEUER 1988) kann, wenn überhaupt, nur mit Hilfe einer ausgeklügelten Forschungsstrategie (vgl. ROTH 1989, 1990) zurückgelegt werden.

Die Modellbildung mit Hilfe künstlicher neuronaler Netzwerke ist noch sehr jung. Empirisch abgesicherte Erkenntnisse liegen kaum vor, wengleich sich – wie gezeigt – die Erkenntnisse anderer wissenschaftlicher Standorte innerhalb dieses Ansatzes verorten lassen.

So gehört ein erheblicher Wagemut dazu, die sportpraktische Relevanz der konnektionistischen Modelle kognitiv-motorischer Prozesse zu diskutieren – ein Wagemut, der sicherlich unwissenschaftlich ist, ohne den in der Praxis allerdings sich nur wenig „bewegen“ würde.

Unter dieser Voraussetzung können beispielhaft einige Ideen für das Technik- und Taktiktraining (und nur darum kann es gehen) abgeleitet werden. Nach JORDANS Modell stehen dem Sportler und seinem Trainer prinzipiell drei verschiedene Möglichkeiten der Beeinflussung interner Prozesse zur Verfügung (vgl. Abb. 2): Die Intention, die Umweltbedingungen und die Fehlerrückmeldung.

Beim *Neulernen* geht es darum, ein intendiertes Bewegungsergebnis bei einem bestimmten Umweltzustand in die adäquate Muskelinnervation zu überführen. Wie wir gesehen haben, ist dazu eine gut ausgebildete Vorstellung der jeweiligen Bewegung vonnöten, eine allgemeine Bewegungserfahrung unterstützt dabei den Abstraktionsprozeß. Dabei ist darauf zu achten, daß die Rückmeldung des Fehlers „in der Sprache“ der Bewegungsvorstellung des Athleten formuliert ist.

Die *Stabilisierung* einer Technik aus den geschlossenen Sportarten würde im Modell bedeuten, daß die irrelevanten Komponenten des Status-Vektors die Ausgabe der *action units* möglichst wenig beeinflussen sollen. Die Gewichte zwischen den durch sie erregten Neuronen und den *hidden units* müßten dazu im Lernverlauf zu Null werden, was vom Netz aber nur erkannt werden kann, wenn sie unregelmäßig erregt werden. Die Gewichte innerhalb des Bewegungssteuerungsnetzes sollten dagegen möglichst konstante und korrekte Werte erreichen, was eine hohe Zahl an Iterationen voraussetzt. Rückübersetzt in die Trainingspraxis hieße dies, daß die zu stabilisierende Übung oft wiederholt werden müßte und daß potentielle störende Einflüsse des Bewegungsverlaufs (Zwischenrufe der Zuschauer, psychischer Druck usw.) während des Trainings in unregelmäßigen Abständen und an verschiedenen Stellen eingesetzt werden sollten.

In den offenen Sportarten steht das Finden von variablen, jeweils situationsangepaßten *Technikvariationen* im Vordergrund. Für das Modell bedeutet dies, in dem potentiell unendlich-dimensionalen Status-Vektor die für das Erreichen des Bewegungsziels bedeutsamen Komponenten herauszufiltern. Zu prüfen wäre hier, ob ein allmähliches „Verbreitern“ des Status-Vektors, ein Unterstützen einzelner seiner Komponenten durch Ko-Aktivierung anderer Neuronen oder ähnliche Maßnahmen zu einem Lernerfolg führen. Oft mag allerdings auch schon das Ziel selbst (das man sich in ähnlichen Kategorien wie „Wirf ein Tor!“ vorstellen kann) falsch gewesen sein. Damit sind aber endgültig die Grenzen der Vorhersagekraft von JORDANS Modell erreicht, möglicherweise können hier andere Netzarchitekturen (z.B. Mustererkennungsnetze mit Aufmerksamkeitsparametern, vgl. CARPENTER/GROSSBERG 1991) bessere Dienste leisten.

Resümierend bleibt festzuhalten, daß die prinzipielle Eigenschaft neuronaler Netzwerke, komplexe sportmotorische Bewegungsausführungen sparsam und angemessen modellieren zu können, eine beachtliche Rückwirkung auf die Theorien motorischer Kontrolle und motorischen Lernens haben wird. Dabei liegen mit fortschreitender Entwicklung gerade durch die Methode der Computersimulation theoretisch fundierte Antworten auf sportpraktische Fragestellungen im Bereich des Möglichen.

¹So der Untertitel der Bände von RUMELHART/MCCLELLAND u.a. bzw. MCCLELLAND/RUMELHART u.a. (1986) über parallele, verteilte Prozesse.

²In dieser verkürzten Darstellung soll weder auf die unterschiedlichen Neuronenmodelle mit verschiedenen Integrations-, Schwellenwert- und Zustandsfunktionen eingegangen noch die Tatsache erwähnt werden, daß einzelne Netzarchitekturen doch globale Information benutzen (z. B. globaler Zeittakt, Information über Zustände anderer Neuronen).

³Der Begriff „Abbildung“ wird hier und im folgenden in seinem mathematischen Sinn gebraucht, bedeutet also soviel wie „Zuordnung“ oder „Funktion“. Die zu lernende Abbildung ist also die Umkehrrelation der Umweltfunktion, wobei hier JORDAN von der „Inversen“ spricht, da es sich für mehrerer Eingabevektoren um Gleichungssysteme in Matrixform handelt. Ganz korrekt müßte es Pseudo-Inverse heißen, da nicht quadratische Matrizen auch nicht invertierbar sind.

Literatur

- BULLOCK, D./GROSSBERG, S. (1988): Neural dynamics of planned arm movements: Emergent invariants and speed-accuracy properties during trajectory formation. In: *Psychological Review* 95, 49-90
- BULLOCK, D./GROSSBERG, S. (1991): Adaptive neural networks for control of movement trajectories invariant under speed and force rescaling. In: *Human Movement Science* 10, 3-54
- CARPENTER, G./GROSSBERG, S. (1991): Pattern recognition by self-organizing neural networks
- GAUDIANO, P./GROSSBERG, S. (1992): Adaptive vector integration to endpoint: Self-organizing neural circuits for control of planned movement trajectories. In: *Human Movement Science* 11, 141-155
- GIBSON, J. J. (1982): *Wahrnehmung und Umwelt*
- HEBB, D. O. (1949): *The organisation of behavior*
- HEUER, H. (1988): Motorikforschung zwischen Elfenbeinturm und Sportplatz. In DAUGS, R. (Red.): *Neuere Aspekte der Motorikforschung*, 52-69
- HIRAYAMA, M./KAWATO, M./JORDAN, M. I. (1993): The cascade neural network model and a speed-accuracy trade-off of arm movements. In: *Journal of Motor Behavior* 25, 162-174
- JORDAN, M. I. (1989): Motor learning and the degrees of freedom problem. In: JEANNEROD, M. (Hrsg.): *Attention and performance XIII*. Hillsdale, NJ., 796-836
- JORDAN, M. I./RUMELHART, D. E. (1992): Forward models: Supervised learning with a distal teacher. In: *Cognitive Science* 16, 307-354
- KAWATO, M./MAEDA, Y./UNO, Y./SUZUKI, R. (1990): Trajectory formation of arm movement by cascade neural network model based on minimum torque-change criterion. In: *Biological Cybernetics* 62, 257-288.
- KÜNZEL, S. (1994): Zum Erklärungswert konnektionistischer Modelle für die Bewegungskontrolle und das Bewegenserlernen im Sport. (unveröffentlichte Examensarbeit)
- MCCLELLAND, J. L./RUMELHART, D. E./THE PDP RESEARCH GROUP (Hrsg.) (1986): *Parallel distributed processing: Explorations in the microstructure of cognition*. Vol. 2. Cambridge
- MORASSO, P./SANGUINETI, V. (1992): Neural models of distributed motor control. In: STELMACH, G.E./REQUIN, J. (Hrsg.): *Tutorials in Motor Behavior II*. Amsterdam, 3-30.

- PARKS, R. W./LONG, D. L./LEVINE, D. S./CROCKETT, D. J./MCGEER, E. G./MCGEER, P. L./DALTON, I. E./ZEC, R. F/ BECKER, R. E./COBURN, K. L./SILER, G./NELSON, M. E./BOWER, J. M. (1991): Parallel distributed processing and neural networks: Origins, methodology and cognitive functions. In: *International Journal of Neuroscience* 60, 195-214
- ROJAS, R. (1993): Theorie der neuronalen Netze
- ROTH, K. (1989): Taktik im Sportspiel. Schorndorf
- ROTH, K. (1990): Externe Validität und Problemkomplexität. In: *Sportwissenschaft* 20, 281-299
- RUMELHART, D. E./MCCLELLAND, J. L./THE PDP RESEARCH GROUP (Hrsg.) (1986): Parallel distributed processing: Explorations in the microstructure of cognition. Volume 1
- RUTKOWSKA, J. C.: Action, connectionism and enaction: A developmental perspective. In: CLARK, A./LUTZ, R. (Hrsg.): *Connectionism in context*. London 1992, 17-36
- SCHEERER, E. (1993): Mentale Repräsentation in interdisziplinärer Perspektive. In: *Zeitschrift für Psychologie* 201, 136-166
- SCHMIDT, R. A. (1975): A schema theory of discrete motor skill-learning. In: *Psychological Review* 82, 229-261
- SCHMIDT, R. A. (1988²): Motor control and learning
- SCHNEIDER, W. (1987): Connectionism: Is it a paradigm shift for psychology? In: *Behavior Research Methods, Instruments, & Computers* 19, 73-83
- SHEA, J. B./MORGAN, R. L. (1979): Contextual interference effects on the acquisition, retention, and transfer of a motor skill. In: *Journal of Experimental Psychology: Human Learning and Memory* 5, 179-187
- TURVEY, M.T. (1977): Preliminaries to a theory of action with reference to vision. In: SHAW, R./BRANSFORD, J. (Hrsg.): *Perceiving, acting, and knowing. Toward an ecological psychology* 211-265