

## Vergleich von MATLAB® und DataEngine® bei der Model- lierung von Wettkampfleistungen im Schwimmen

### Einleitung

Anpassungsprozesse im sportlichen Training und die Entwicklung des Leistungsverlaufs sind abhängig von der zeitlichen und inhaltlichen Gestaltung der Belastungen im täglichen Training. Die Zusammenhänge zwischen Trainings- und Leistungschronologie sind dabei von komplexer Natur und sehr individuell. Daher wird für die Analyse von Trainingsprozessen in jüngerer Vergangenheit vermehrt von einer nichtlinearen systemtheoretischen Betrachtungsweise ausgegangen. In diesem Zusammenhang findet auch die Verwendung von nichtlinearen mathematischen Methoden vermehrt Eingang in die trainingswissenschaftliche Analyse. Insbesondere die künstlichen neuronalen Netze scheinen für diesen Bereich vielversprechend zu sein. Neuronale Netze oder artificial neuronal networks stellen „informationsverarbeitende Systeme dar, deren Struktur und Funktionsweise tierischer und menschlicher Gehirne nachempfunden sind“ (Nauck et al., 1996). Im speziellen sind Anwendungen des Multilayer-Perceptron (MLP) Netzmodells für trainingswissenschaftliche Fragestellungen bekannt (Hohmann et al., 2000; Edelmann-Nusser et al., 2000, 2002, 2006; Silva et al., 2007). Hierbei handelt es sich um ein Netzmodell, das zur Lösung komplexer Problemstellungen eine oder mehrere verdeckte Schichten („hidden layers“) mit Neuronen besitzt, wie in Abb. 1 dargestellt.

Die Verbindungen des Netzmodells existieren nur von der Eingabeschicht in Richtung der Ausgabeschicht, es ist ein Feed-Forward Netz. Ein solches Netz stellt in Abhängigkeit von der Wahl der verdeckten Schichten und Anzahl der Neuronen einen „universellen Approximator“ dar, d.h. es ist in der Lage nahezu jede stetige Funktion zu approximieren (Nauck et al., 1996). Während des überwachten Lernens wird dem Netz zu jedem Eingabemuster das zugehörige Ausgabemuster präsentiert. Das Netz „lernt“ implizit die Zusammenhänge zwischen den Ein- und Ausgabemustern und bildet die Informationen in seinen Synapsengewichten, d.h. den Verbindungen zwischen den einzelnen Neuronen, ab. Häufig findet sich die Anwendung des Backpropagation Algorithmus beim überwachten Lernen. Dabei wird das Fehlersignal an der Ausgabeschicht rückwärts durch das Netz „propagiert“ und entsprechend die einzelnen Gewichte verändert. Ziel des Lernens ist es, dass das Netz im

„trainierten“ Zustand auf unbekannte Eingangsmuster mit adäquaten Ausgabemustern antwortet. Die Generalisierbarkeit des Netzes muss anschließend über eine entsprechende Validierung beurteilt werden. Praktische Probleme beim Einsatz solcher Netze zeichnen sich häufig durch das Fehlen einer ausreichenden Anzahl von Datensätzen aus, da das Netz in Abhängigkeit von seinen Freiheitsgraden, d.h. der Anzahl der Synapsengewichte, stets eine Mindestzahl an Daten für das Training benötigt.

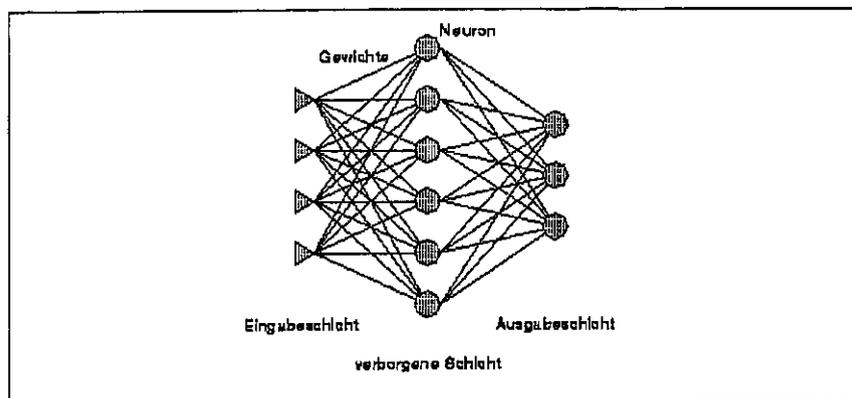


Abb. 1: Multilayer-Perceptron, schematische Darstellung

Die Einsatzgebiete Neuronaler Netze im Rahmen trainingswissenschaftlicher Fragestellungen lassen sich überwiegend in die Bereiche Statusdiagnostik, Prozessdiagnostik und Talentforschung abgrenzen (Bügner, 2005). Anwendungen im Bereich der Statusdiagnostik lassen sich beim letztgenannten Autor finden, ebenso für den Bereich der Talentforschung. Hier sind auch Untersuchungen einer internationalen Arbeitsgruppe bekannt (Silva et al., 2007). Für den Bereich der Prozessdiagnostik lassen sich insbesondere Einzelfallanalysen von Hochleistungsschwimmern finden (Hohmann et al., 2000; Edelmann-Nusser et al., 2000, 2002, 2006; Bügner, 2005). Dabei wurde der Einfluss des Trainings in der Wettkampfvorbereitungsphase, d.h. während der Hochbelastungs- und während der Taperphase auf die nachfolgende Wettkampfleistung untersucht. Die Ergebnisse zeigten zum Teil sehr gute Übereinstimmungen zwischen dem Modell und den realen Wettkampfleistungen. Dabei war es sogar möglich die Wettkampfleistung bei den Olympischen Spielen 2000 und 2004 bis auf einige Zehntel genau zu prognostizieren (Edelmann-Nusser et al., 2002, 2006). Neuronale Netze scheinen daher für den Bereich der Trainingsoptimierung und der Prognose von Wettkampfleistungen vielversprechend zu sein.

Verglichen mit anderen Anwendungsfeldern von Neuronalen Netzen fällt im Trainingsprozess von Hochleistungssportlern üblicherweise eine geringe An-

zahl von Datensätzen an, daher wurde in den vorgestellten Untersuchungen für die Netzmodelle jeweils eine Kreuzvalidierung nach dem leave-one-out Prinzip mit der DataEngine® Software vorgenommen. Dieses Vorgehen ist jedoch durch einen hohen zeitlichen und arbeitstechnischen Aufwand gekennzeichnet. Für ausführlichere Analysen bzw. eine Ausweitung auf andere Sportler wäre daher eine programmtechnische Automatisierung der leave-one-out Kreuzvalidierung wünschenswert. Dafür bieten sich z.B. „mathematische Programmiersprachen“ wie MATLAB® an.

Ziel dieser Arbeit ist es, mit exemplarisch vorhandenen Daten aus dem Schwimmen die Wettkampfleistungen unter Verwendung der Programmumgebungen DataEngine® und MATLAB® zu modellieren und die Ergebnisse untereinander zu vergleichen.

## Methoden

Die Durchführung der Modellierung erfolgte in Anlehnung an die Untersuchung von Edelmann-Nusser et al. (2000) mit Daten aus dem Schwimmsport. Dafür standen die Wettkampfdaten einer Hochleistungsschwimmerin über 200m Rücken zur Verfügung. Die insgesamt 19 Wettkampfleistungen wurden über einen Zeitraum von mehreren Jahren aufgezeichnet. Entsprechend des LEN Punktesystems wurden die Wettkampfzeiten auf eine Punkteskala transformiert. Die Formel der Fina Point Scoring zur Umrechnung lautet  $P=1000*(B/T)^3$ , wobei P die erbrachte Zeit in LEN Punkten darstellt, B die zugrundeliegende momentane Weltbestzeit und T die geschwommene Zeit. Über diesen Zeitraum standen zudem die Trainingsdaten der Schwimmerin aus einer quantitativ kategorialen Trainingsprotokollierung zur Verfügung. Diese bestanden aus den wöchentlichen Umfängen (Kilometer bzw. Stunden) in den folgenden Kategorien: Grundlagenausdauertraining leicht oberhalb der aeroben Schwelle (ga1), Grundlagenausdauertraining an und leicht über der anaeroben Schwelle (ga2), anaerobes Schnelligkeits- und Schnelligkeitsausdauertraining (ga3), Krafttraining an Land (h\_kraft) und allgemeines Konditionstraining an Land (h\_land).

Im Rahmen dieser Untersuchung wurde der Einfluss des Trainings in der Hochbelastungsphase, d.h. in der 3. und 4. Woche vor dem Wettkampf auf die Wettkampfleistung berücksichtigt. Als Netzmodell wurde ein MLP mit einer Eingabeschicht, einer verdeckten Schicht und einer Ausgabeschicht gewählt. Da für jede Trainingswoche die Umfänge in den fünf Trainingskategorien vorliegen, ergibt sich für die Eingabeschicht eine Anzahl von zehn Neuronen. Die Wettkampfleistung wird über ein Neuron in der Ausgabeschicht repräsentiert und für die verdeckte Schicht wurden zwei Neuronen ausgewählt. Die Übergangsfunktionen waren für die Eingangs- und Ausgangsschicht linear und für die verdeckte Schicht wurde der Tangens-Hyperbolicus

als Transferfunktion ausgewählt. Damit ergibt sich für das Netzmodell eine Anzahl von 22 Freiheitsgraden (d.h. Anzahl der Verbindungen von der Eingangs- zur Ausgangsschicht). Da zum Training des Netzes mindestens die doppelte Anzahl der Freiheitsgrade als Datensätze zur Verfügung stehen sollte, wurde das Netz zunächst mit Trainings- und Wettkampfdaten einer anderen Sportlerin vortrainiert. Von dieser Sportlerin lagen weitere 23 Datensätze bestehend aus Wettkampfleistungen und den zugehörigen Trainingsumfängen vor.

Die Validierung des Netzes erfolgte dann nach der leave-one-out-Methode mit dem folgenden Vorgehen:

Die 19 Datensätze der zu beobachtenden Hochleistungsschwimmerin wurden für die Kreuzvalidierung so eingeteilt, dass 18 Datensätze zum Training des künstlichen Neuronalen Netzes eingesetzt werden und ein Datensatz als Testdatensatz dient. Das Vortraining des Neuronalen Netzes bestand aus 23 + 18 Datensätzen. Für das Training wurde der Backpropagation-Algorithmus mit zufälliger Präsentationsreihenfolge der Trainingsmuster als Lernverfahren und eine Gewichtsinitialisierung zufällig und innerhalb von  $-0,1$  bis  $+0,1$  gewählt. Die Lernrate betrug  $0,1$  bei einem Gewichtsdecay von  $0,999999$ . Es wurden insgesamt 10000 Lernschritte durchlaufen, davon dienten 1000 dem Vortraining.

Aus programmtechnischer Sicht besteht der Unterschied darin, dass in DataEngine® die Datensätze für jeden Schritt der leave-one-out Kreuzvalidierung manuell vorverarbeitet werden müssen. In der MATLAB®-Umgebung kann die Prozedur dagegen über ein Skript automatisiert werden.

Als Ergebnisse der Kreuzvalidierung werden dann die Fehler als Abweichungen zwischen modellierten und realen Leistungswerten untereinander verglichen.

## Ergebnisse

Tabelle 1: Ergebnisse der Kreuzvalidierung mit 19 Testdatensätzen in LEN Punkten von DataEngine® im Vergleich zu den Zielwerten

Netzvorhersage	Zielwert	Fehler
913	882	31
958	901	57
857	848	9
989	905	84
907	839	68
810	790	20
921	888	33
905	861	44
880	839	21
855	844	11
962	870	92
905	862	43
852	849	3
927	888	61
912	875	37
884	833	61
917	905	12
919	877	42
885	856	29

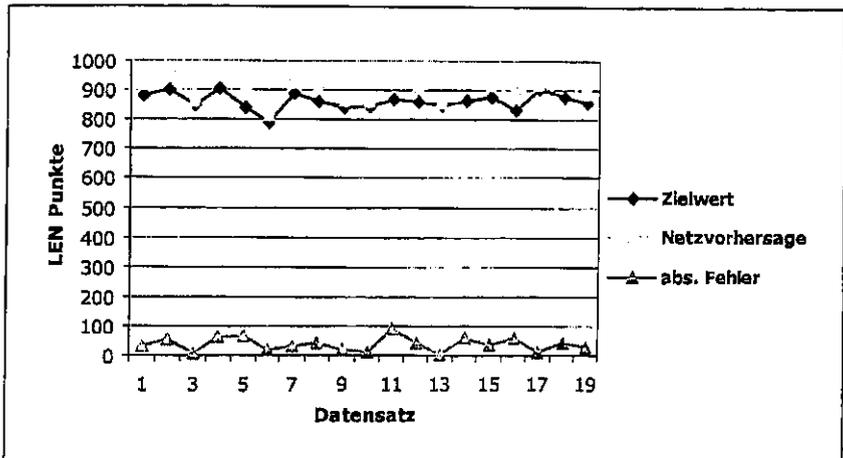


Abb. 2: Visualisierung der Ergebnisse der Kreuzvalidierung mit DataEngine®

Tabelle 2: Ergebnisse der Kreuzvalidierung mit 19 Testdatensätzen in LEN Punkten von MATLAB® im Vergleich zu den Zielwerten

Netzvorsage	Zielwert	Fehler
883	882	19
883	901	38
862	848	14
791	905	114
877	839	38
854	790	64
851	888	37
844	861	17
878	839	39
875	844	31
864	870	6
875	882	13
881	849	32
832	886	54
888	875	8
882	833	29
873	905	32
856	877	21
871	858	15

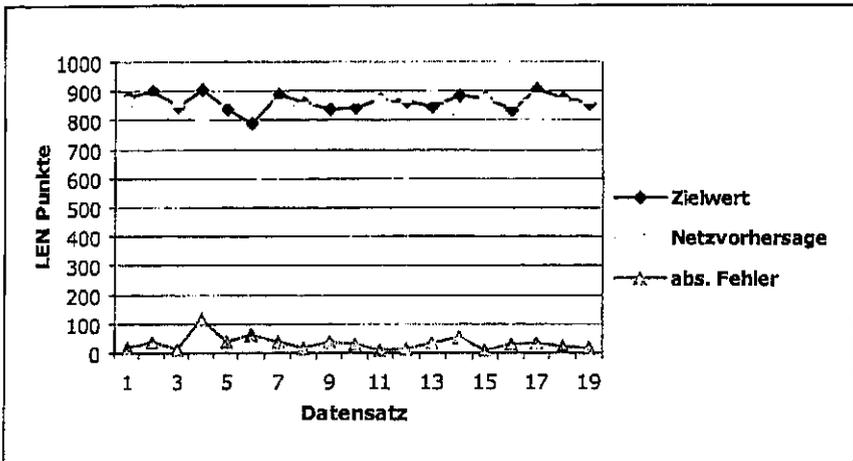


Abb. 3: Visualisierung der Ergebnisse der Kreuzvalidierung mit MATLAB®

Anhand der Tabellen 1 und 2 und den Abbildungen 2 und 3 ist ersichtlich, wie die 19 Testdatensätze im Vergleich zur eigentlichen Wettkampfleistung von

dem erzeugten künstlichen Neuronalen Netz modelliert wurden. Der Fehlerverlauf ist in Abbildung 4, im Vergleich der beiden Programme, dargestellt.

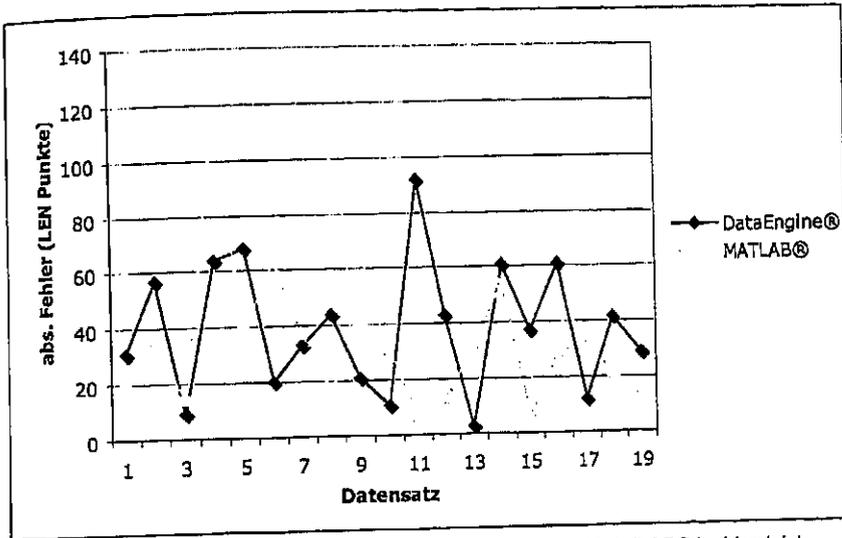


Abb. 4: Modellfehler unter Verwendung von DataEngine® und MATLAB® im Vergleich

Der mittlere absolute Fehler über die 19 modellierten Wettkampfleistungen beträgt in MATLAB® etwa 32,5 (SD ± 25,0) LEN-Punkte und in DataEngine ca. 38 (SD ± 25,0) LEN-Punkte.

## Diskussion

Es kann festgestellt werden, dass die Modellierungen der Wettkampfleistung im Schwimmen unter Verwendung von zwei verschiedenen Programmumgebungen ähnliche Ergebnisse für die Modellfehler ergeben. Der Modellfehler unter Verwendung der MATLAB®-Umgebung ist dabei etwas geringer. Ursachen für die vorhandenen Abweichungen können in den programmtechnisch spezifischen Konfigurationsmöglichkeiten für die Architektur des Netzes und für den Trainingsalgorithmus vermutet werden. Obwohl versucht wurde, die Konfigurationsparameter möglichst adäquat von der DataEngine®-Umgebung auf die MATLAB®-Umgebung zu übertragen, lässt sich die programminterne Verarbeitung dieser Parameter nicht immer vollständig von außen nachvollziehen. Ohne eine vollständige Kenntnis der dahinterstehenden Algorithmen, kann dieser Sachverhalt nicht zufriedenstellend aufgeklärt werden. Aufgrund der breiteren Konfigurationsmöglichkeiten in der MATLAB®-Umgebung, und der Automatisierungsmöglichkeit für Schritte der Datenvorverarbeitung ur

des Netztrainings, sowie der Ergebnisvisualisierung scheint diese für die Modellierung von Wettkampfleistungen unter Verwendung der leave-one-out Kreuzvalidierungsmethode Vorteile gegenüber der DataEngine®-Umgebung zu besitzen. Hier ergibt sich die Möglichkeit für weiterführende Modellierungen mit annehmbarem Arbeitsaufwand auch größere Mengen von Datensätzen zu verarbeiten bzw. Datensätze von anderen Sportlern zu verwenden.

Inhaltlich muss für die Ergebnisse der Modellierung der Wettkampfleistung festgestellt werden, dass sich zum Teil hohe Abweichungen zwischen Modellleistung und der realen Leistung ergeben. Daraus resultiert auch ein eher hoher mittlerer Gesamtfehler. Es muss angemerkt werden, dass in diesem Fall nur die Trainingsdaten aus der Hochbelastungsphase, d.h. der Wochen 3 und 4 vor der Wettkampfleistung berücksichtigt wurden. Eine Ausweitung des Wettkampfvorbereitungszeitraums, der für die Modellierung berücksichtigt wird, sollte sich auch in einer verbesserten Modellanpassung widerspiegeln. Zudem stellt die eher geringe Anzahl von Datensätzen einer Sportlerin ein grundlegendes Problem bei einer derartigen Modellierung dar.

## **Autoren**

ANNE DOBRITZ, NICO GANTER, PROF. DR. JÜRGEN EDELMANN-NUSSER: Institut für Sportwissenschaft, Otto-von-Guericke-Universität Magdeburg

GEORG RUß: Institut für Wissens- und Sprachverarbeitung, Otto-von-Guericke-Universität Magdeburg

## **Literatur**

- Bügner, J. (2005). Nichtlineare Methoden in der trainingswissenschaftlichen Diagnostik –Mit Untersuchungen aus dem Schwimmsport-. Universität Potsdam
- Edelmann-Nusser, J., Hohmann, A. & Henneberg, B. (2000). Prognose der olympischen Wettkampfleistung im Schwimmen. *Leistungssport*, 3, 20-23
- Edelmann-Nusser, J., Hohmann, A. & Henneberg, B. (2002). Modeling and Prediction of Competitive Performance in Swimming Upon Neural Networks. *European Journal of Sport Science*, vol. 2, issue 2
- Edelmann-Nusser, J., Hohmann, A. & Henneberg, B. (2006). Modellierung von Wettkampfleistung im Schwimmen bei den olympischen Spielen 2000 und 2004 mittels neuronaler Netze. *Leistungssport*, 36 (2), 45-50
- Hohmann, A., Edelmann-Nusser, J. & Henneberg, B. (2000). A Nonlinear Approach to the Analysis and Modeling of Training and Adaptation in

Swimming. In R. Sanders & Y. Hong (Eds.), *Application of Biomechanical Study in Swimming*. Proceedings of XVIII International Symposium on Biomechanics in Sports (pp. 31-38). Hong Kong: Chinese University Press

Nauck, D., Klawonn, F. & Kruse, R. (1996). *Neuronale Netze und Fuzzy-Systeme*. Braunschweig: Vieweg-Verlag.

Silva, A. J., Costa, A. M., Oliveira, P. M., Reis, V. M., Saavedra, J., Perl, J., Roubua, A. & Marinho, D. A. (2007). The use of neural network technology to model swimming performance. *Journal of Sports Science and Medicine*, 6, 117-125