
Multivariate Zeitreihenmodellierung von Trainingswirkungen mit neuronalen Netzen

(AZ 070520/10)

Benjamin Haar (Projektleiter) & Wilfried W. Alt

Universität Stuttgart, Institut für Sport- und Bewegungswissenschaft

Einleitung

Modelle zur Analyse und Prognose von Trainingswirkungen sind vielversprechende Verfahren für eine individuelle Optimierung der Belastungsgestaltung (Banister et al., 1975; Mester & Perl, 2000; Edelmann-Nusser et al., 2000). Die starken Vereinfachungen der antagonistischen und non-parametrischen Modelle führen aber zu einer geringen Modellgüte und Prognoseleistung. Forschungsbedarf besteht daher hinsichtlich neuer multifaktorieller Modelle, die den komplexen und dynamischen Trainingsprozess hinreichend abbilden.

Künstliche neuronale Netze (KNN) haben sich als Methode zur Analyse und Prognose von nichtlinearem und dynamischem Systemverhalten bewährt (Zhang et al., 1999). Das Ziel dieser Arbeit ist es, den Zusammenhang zwischen Beanspruchung und sportlicher Leistungsfähigkeit mit KNN verlaufsorientiert abzubilden und die Leistungsentwicklung vorherzusagen.

Material und Methoden

An dieser Studie nahmen drei hochtrainierte Triathletinnen und -athleten teil (27 ± 10 Jahre; $VO_2\text{max} = 3,72 \pm 0,15 \text{ l}\cdot\text{min}^{-1}$). Während des dreimonatigen Untersuchungszeitraums wurde täglich die Trainingsbeanspruchung in vier Kategorien (Laufen, Radfahren, Schwimmen und Krafttraining) anhand der Herzfrequenz und des zeitlichen Umfangs dokumentiert (Banister & Hamilton, 1985). Die Erholungs-Beanspruchungsbilanz der Versuchspersonen wurde jeden dritten Tag an 30 Messzeitpunkten mit einem Fragebogen erfasst (Kellmann & Kallus, 2000). Die maximale Sauerstoffaufnahme wurde als Maß für die Ausdauerleistungsfähigkeit ebenfalls alle drei Tage mit einer Fahrrad-Spiroergometrie bestimmt (Van Schuylenbergh et al., 2004).

Für die multivariate Zeitreihenanalyse wurde ein Backpropagation-Netz eingesetzt. Die Trainingsbeanspruchung und der psychometrisch erfasste Erholungs- und Beanspruchungszustand wurden als Prädiktorvariablen berücksichtigt. Die Dynamik des Trainingsprozesses wurde über den Zusammenhang zwischen der Leistungsfähigkeit und der Leistungsentwicklung abgebildet. Die KNN wurden für jede Athletin und jeden Athleten mit 24 Datensätzen trainiert. Die Entwicklung der Leistungsfähigkeit wurde über vier Messzeitpunkte vorhergesagt.

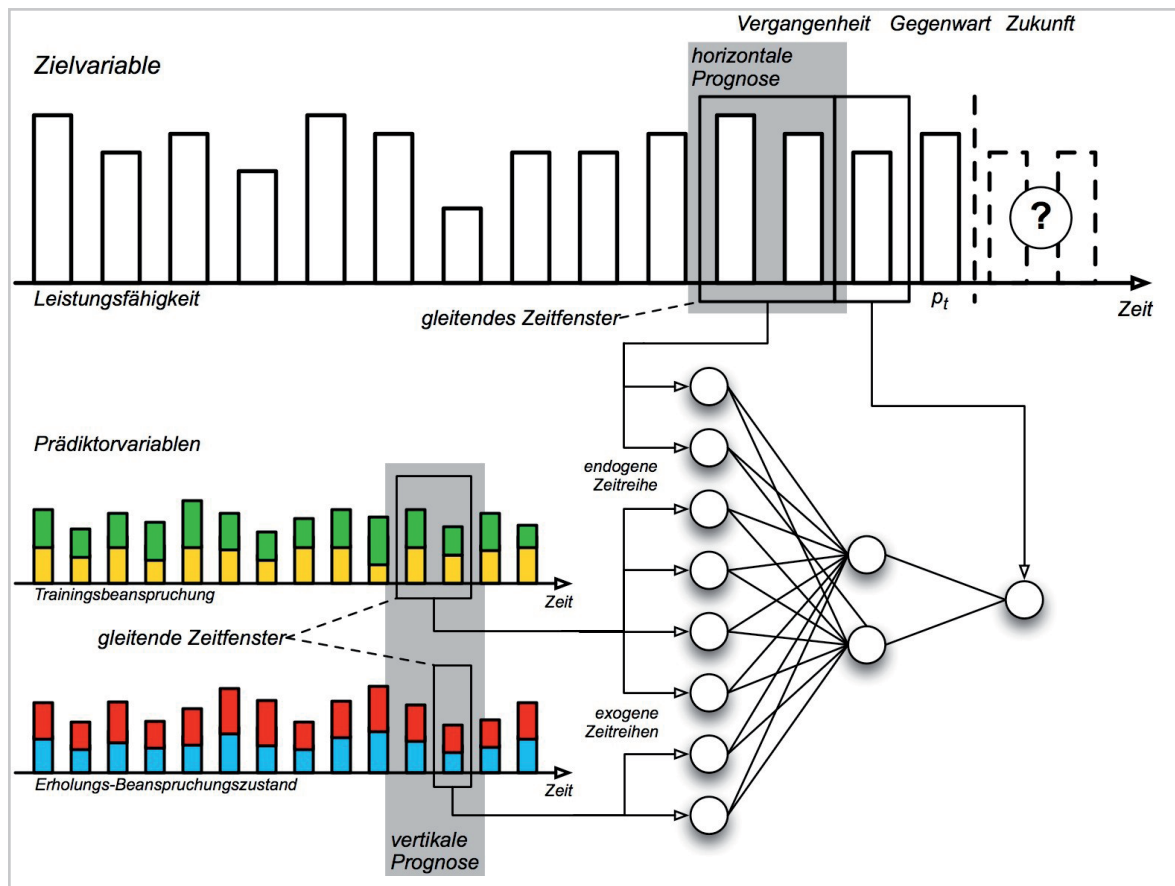


Abb. 1. Schema eines künstlichen neuronalen Netzes zur Analyse und Prognose von Trainingswirkungen.

Durch eine schrittweise Reduktion der Eingabedaten, wurde das multivariate Modellkonzept auf seine Gültigkeit hin geprüft. Die Modellgüte und Prognoseleistung wurden im Vergleich zu den antagonistischen Modellen bewertet.

Ergebnisse

Bei allen Testpersonen wird bei der Analyse und Prognose von Trainingswirkungen mit KNN (KNN-Modell) eine hohe Modellgüte (root mean square error (RMSE = $0,05 \pm 0,02 \text{ l} \cdot \text{min}^{-1}$) und Vorhersagegenauigkeit (RMSE = $0,05 \pm 0,02 \text{ l} \cdot \text{min}^{-1}$) erreicht. Die Reduktion der Eingabedaten führt zu einer abnehmenden Abbildungs- und Prognoseleistung. Modellgüte und Prognoseleistung des KNN-Modells sind im Vergleich zu den antagonistischen Trainings-Wirkungs-Modellen höher.

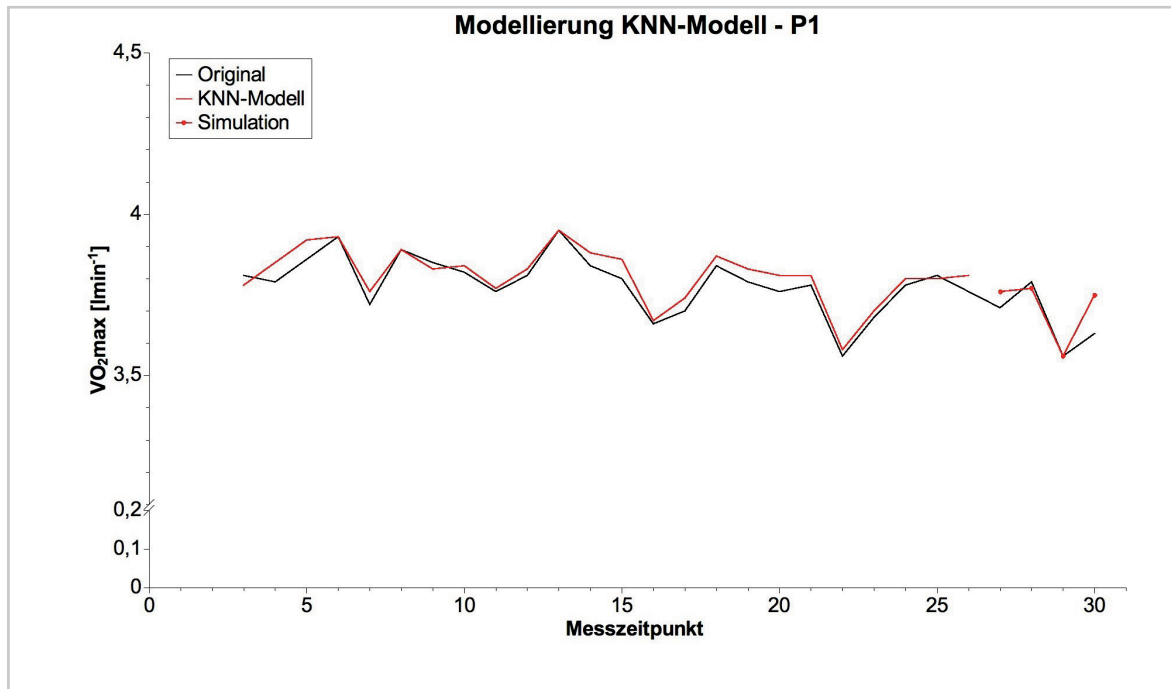


Abb. 2. Beispiel von Versuchsperson 1. Realer, modellierter und prognostizierter Leistungsverlauf.

Diskussion

KNN sind besonders zur verlaufsorientierten Analyse und Prognose von Trainingswirkungen geeignet. Der Vorteil dieser Methode ist in der multivariaten Modellstruktur zu sehen. Durch die differenzierte Berücksichtigung trainingsinduzierter Beanspruchungen und des aktuellen Erholungs- und Beanspruchungszustands wird ein höherer Erklärungswert für die Leistungsentwicklung erreicht. Trainings-Wirkungs-Modelle mit geringerer Komplexität bilden den Leistungsverlauf nur ungenau ab und können die Leistungsentwicklung nicht exakt vorhersagen.

Schlussfolgerung

Simulative Trainings-Wirkungs-Modelle eignen sich für eine individuelle Trainingssteuerung nur dann, wenn sie in hohem Maße die Komplexität und Dynamik des Trainingsprozesses abbilden. Dann bietet sich aber ein praktischer Einsatz vor allem in der kurzfristigen Trainingsplanung oder Wettkampfvorbereitung an.

Literatur

- Banister, E. W., Calvert, T. W., Savage, M. V. & Bach, T. M. (1975). A Systems model of training for athletic performance. *Australian journal of sports medicine*, 7 (3), 57-61.
- Banister, E. W. & Hamilton, C. L. (1985). Variations in iron status with fatigue modelled from training in female distance runners. *European journal of applied physiology and occupational physiology*, 54 (1), 16-23.
- Edelmann-Nusser, J., Hohmann, A., & Henneberg, B. (2001). Prognose der olympischen Wettkampfleistung im Schwimmen. *Leistungssport*, 31 (3), 20-23.
- Mester, J. & Perl, J. (2000). Grenzen der Anpassungs- und Leistungsfähigkeit des Menschen aus systemischer Sicht. *Leistungssport*, 30 (1), 43-51.
- Kellmann, M. & Kallus, K. W. (2000). *Der Erholungs-Belastungs-Fragebogen für Sportler*. Frankfurt: Verlag Swets Test service.
- Van Schuylenbergh, R., Eynde, B. V. & Hespel, P. (2004). Prediction of sprint triathlon performance from laboratory tests. *European journal of applied physiology*, 91 (1), 94-99.
- Zhang, G., Patuwo, B. E. & Hu, M. Y. (1998). Forecasting with artificial neural networks: The state of the art. *International journal of forecasting*, 14, 35-62.