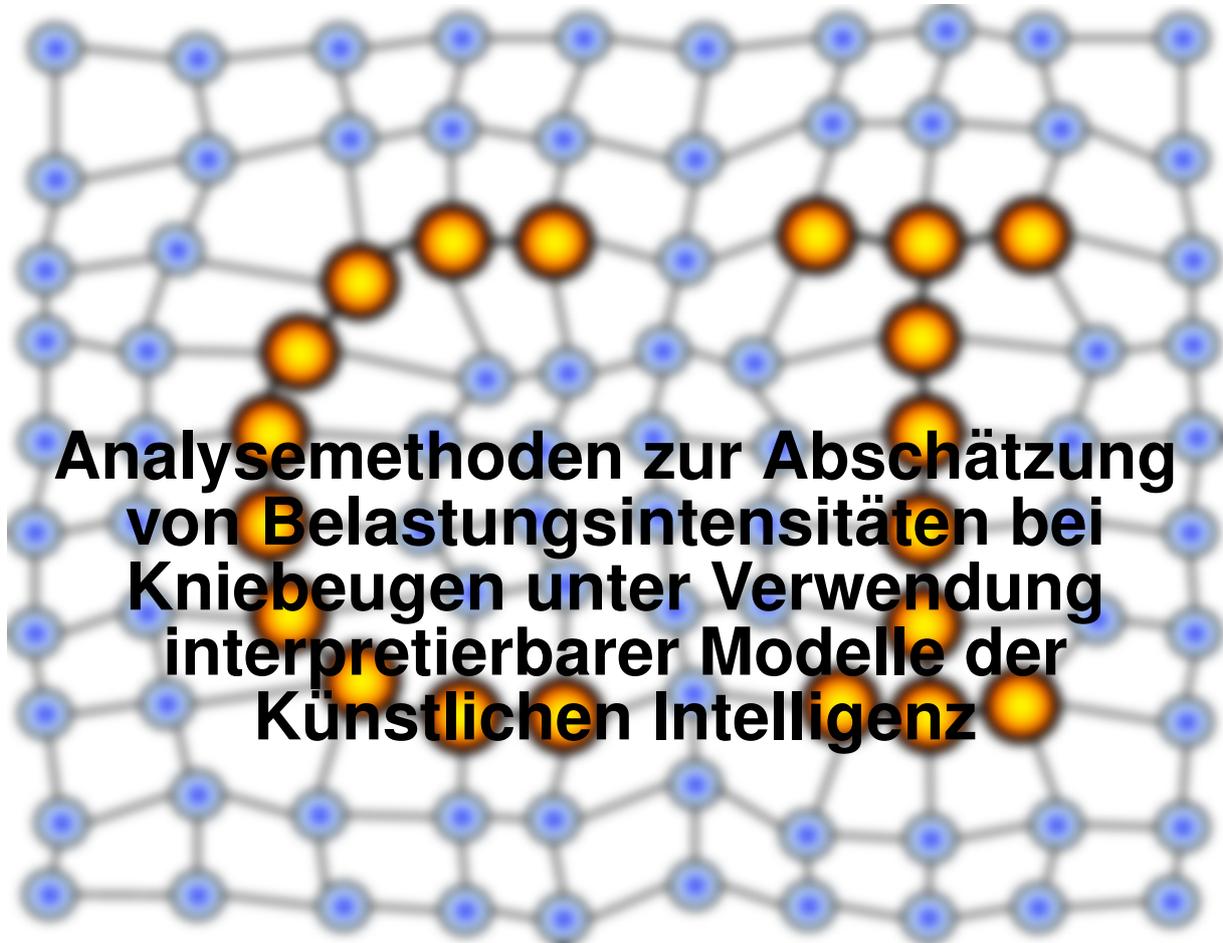


MACHINE LEARNING REPORTS



Report 01/2020

Submitted: 01.07.2020

Published: 08.07.2020

Norman Hofmann ¹, Jalal Alhakeem ², Heike Hermsdorf ¹, Danny Möbius ^{1*}, Steffen Öhmichen ², Henry Schulz ², Marika Kaden ³, Thomas Villmann ³

(1) Institut für Mechatronik e.V. Chemnitz

Chemnitz, Germany

(2) TU Chemnitz,

Professur Sportmedizin/-biologie

Chemnitz, Germany

(3) SICIM,

Hochschule Mittweida

Mittweida, Germany

Impressum

Publisher: University of Applied Sciences Mittweida
Technikumplatz 17,
09648 Mittweida, Germany

Editor: Prof. Dr. Thomas Villmann
Dr. Frank-Michael Schleif

Technical-Editor: Dr. Frank-Michael Schleif
Contact: fschleif@techfak.uni-bielefeld.de
URL: <http://techfak.uni-bielefeld.de/~fschleif/mlr/mlr.html>
ISSN: 1865-3960

Analysemethoden zur Abschätzung von Belastungsintensitäten bei Kniebeugen unter Verwendung interpretierbarer Modelle der Künstlichen Intelligenz

Norman Hofmann¹, Jalal Alhakeem², Heike Hermsdorf¹, Danny Möbius^{1*},
Steffen Öhmichen², Henry Schulz², Marika Kaden³, Thomas Villmann³

¹Institut für Mechatronik e.V. Chemnitz

² TU Chemnitz, Professur Sportmedizin/-biologie

³ SICIM, Hochschule Mittweida

1 Einleitung und Problemstellung

In vielen Sportarten ist die Beinstreckung eine zentrale Komponente bei der Erreichung maximaler Leistungen, wie z.B. maximale Laufgeschwindigkeit. Dabei wird die beinstreckende Muskulatur primär über Formen der Kniebeugen mit zusätzlichen Gewichten trainiert. Für die Steigerung der Maximalkraft, orientiert sich die Höhe der Trainingsgewichte prozentual an der individuell bisher maximal erreichten Leistung des Athleten. Somit ist es notwendig, dieses Maximalgewicht so genau wie möglich zur Trainingssteuerung zu ermitteln, um ein optimales und zielgerichtetes Training zu gewährleisten und ein Übertraining bzw. Überlastungsschäden zu verhindern [1, 2]. Die Bestimmung der Maximalkraft ist jedoch schwierig und unterliegen immer einer gewissen Fehlertoleranz, da sie von vielen Einflussfaktoren abhängt (z.B. Tagesform, Trainingsumgebung, etc.). Weiter sind Testmethoden zur Ermittlung der Maximalkraft, wie z.B. das One-Repetition-Maximum (1RM), sehr zeitintensiv und bergen ein hohes Verletzungsrisiko [3]. Extrapolationsmethoden aus dem submaximalen Bereich bieten teilweise eine Alternative bei eingeschränkter Vorhersagegenauigkeit [4, 5]. Weiter schränken oft isometrische und isokinetische Kraftdiagnostikmethoden aufgrund der Messapparatur Bewegungsausführung ein, so dass die Aussagekraft gemindert ist [6]. Andererseits unterscheidet sich die Bewegungsausführung im Maximalkraftbereich (MKB) von der im submaximalen Bereich (SMKB) z.B. durch verminderte Geschwindigkeit und Präzision. Eine entsprechende Auswertung könnte helfen den MKB zu erfassen. Messapparaturen für die isokinetische Kraftdiagnostik, die eine freie Bewegungsausführung gestatten sind oft kamerabasiert oder basieren auf einem Motion-Capture-System (MCS). Die Auswertung entsprechender digitaler Daten gestaltet sich im Allgemeinen schwierig (komplexe Bildverarbeitung bzw. Trajektorienanalyse im MCS). In der vorliegenden Untersuchung wird der Einsatz eines interpretierbaren KI-Modells zur Erkennung des MKB beim Kniebeugen mit zusätzlichen Langhantelgewicht unter Verwendung eines optischen MCS gekoppelt mit portablen Kraftmessplatten zur Ermittlung der biomechanischen Daten untersucht.

2 Methodik

Für die Untersuchung zur Erkennung des MKB an Hand biomechanischer Daten der Versuchsdurchführung bei den Kniebeugen mit Zusatzgewicht gab jeder Sportler vorab sein geschätztes Maximalgewicht an. Danach absolvierte jeder, nach einer individuell gewählten Erwärmung, 8 Versuche bei 50% seines geschätzten Maximalgewichtes, 3 Versuche bei 70% und im Anschluss entsprechend seiner eigenen Präferenzen zur Gewichtssteigerung jeweils einen Versuch bis zum Erreichen der momentanen Maximallast. Schlussendlich absolvierter jeder Proband zwischen 17 und 20 Kniebeuge (Versuche) mit Gewichten. Die Pausenzeit zwischen den Versuchen lag bei etwa 3:30 bis 4 Minuten. Ein Versuch gilt als gültig, wenn das Gewicht selbständig aus der Hocke wieder in den Stand angehoben wird. Die Bewegung Hocke wiederum ist erfüllt, wenn der Oberschenkel mindestens parallel zum Boden ausgerichtet war. Im Anschluss wurde ein gültiger Versuch als im MKB liegend gekennzeichnet, wenn mindestens 90% der final erzielten Maximallast bewältigt wurde. Andernfalls wurde er dem SMKB zugeordnet. Alle Versuche wurden mit dem folgend beschriebenen biomechanischen Messsystem digitalisiert: Für die Erhebung der Bewegungsdaten und der Interaktionskräfte wurden zwei gekoppelte Messsysteme verwendet. Mit einem optischen MCS (ART) erfolgte die Aufzeichnung der menschlichen Bewegungen, während die Erhebung der Interaktionskräfte bzw. der Bodenreaktionskräfte mit zwei portablen Kraftmessplatten (Kistler) realisiert wurde. Beide Messsysteme arbeiten synchronisiert, räumlich kalibriert und zeichnen mit einer Frequenz von 150Hz die Daten auf. Jeder Proband trägt während einer Messung 17 Markercluster (Targets) auf den jeweiligen Körpersegmenten, um die Bewegungstrajektorien aufzeichnen zu können (siehe Figure 1). Für die biomechanische Modellierung zur Generierung der digitalisierten Bewegungsdaten wurde das Menschmodell Dynamicus eingesetzt [7]. Für jeden Probanden wurde das Modell individuell angepasst, d.h. die anthropometrischen Größen wie Längen, Breiten oder Umfänge werden zur Konfiguration verwendet (siehe Figure 1). Für die Rekonstruktion der Bewegung wurde eine inverse Kinematik angewendet. Die dazugehörige Berechnung der Kräfte und Momente erfolgte ebenfalls über die Berechnung einer inversen Dynamik. Für die Charakterisierung der Versuche wurden schlussendlich die folgenden Modellgrößen herangezogen: die Geschwindigkeit des Center-of-Mass (COM) als Absolutwert sowie in 3-Richtung, die Geschwindigkeit des ersten Thoracal-Wirbels der Wirbelsäule (T1) sowie die Winkelgeschwindigkeit beim Öffnen der Gelenke, Hüfte, Knie und Sprunggelenke. Von diesen Modellgrößen wurde der Mittelwert, die Standardabweichung und die Schiefe über den Zeitraum der Streckbewegung gebildet. Somit ergibt sich ein Merkmalsprofil für jeden einzelnen Versuch, welches 88 verschiedenen biomechanische und kinematische Kenngrößen (Merkmale) für jeden Versuch umfasst. Diese Versuchsprofile bilden den Lerndatensatz, welcher hinsichtlich der Diskriminierung (Klassifikation) von MKB versus SMKB mit Hilfe eines interpretierbaren künstlichen neuronalen Netzes (KNN) analysiert werden soll. Für die Datenerhebung wurde ein Probandenkollektiv akquiriert, welches aus 10 gesunden und sportlich aktiven Athleten (9 männlich und 1 weiblich), z. T. Kaderstatus, bestand. Die Athleten waren in den Sportarten Kugelstoßen, Gewichtheben und Fitnesssport aktiv. Die erreichten maximalen Lasten lagen in einem Bereich von 72 bis 225kg.

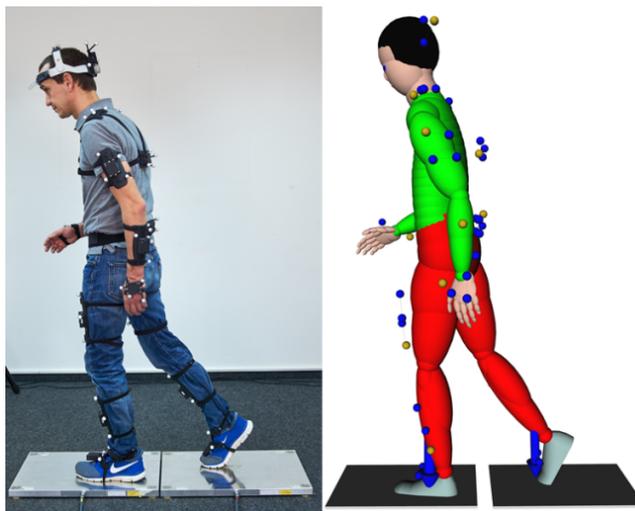


Figure 1: Illustration der Übertragung einer gemessenen Bewegung und gemessener Kräfte auf das Modell

3 Analyse mit Hilfe interpretierbarer Künstlicher Neuronaler Netzwerke

Für KNN bilden Lerndatensätze sogenannten Trainingsaufgaben, die das Modell erlernen soll korrekt wiederzugeben (hier Zuordnung der Versuchsprofile zu den Klassen MKB bzw. SMKB). Dabei agieren KNN oft als sogenannte Black-Box-Verfahren, da die Entscheidungsfindung für den Anwender nicht oder nur teilweise nachvollzogen werden kann. Interpretierbare KNN haben den Vorzug, dass die Entscheidungsfindung transparenter ist und dem Anwender üblicherweise Zusatzinformationen zu diesem Prozess bereitgestellt werden [8, 9]. Diese Zusatzinformationen können weiteren Aufschluss über die Problemstellung liefern. In der vorliegenden Untersuchung wurde als interpretierbares KNN zur Klassifikation das sogenannte Generalized Learning Vector Quantizer (GLVQ) mit adaptiver Datenprojektion verwendet [10, 11], welches als eines der erfolgversprechendsten interpretierbaren KI-Modelle gilt [12]. Als Zusatzinformation generiert der GLVQ aus der erlernten Datenprojektion Korrelationswerte zwischen den Kenngrößen, die zur Entscheidungsfindung wesentlich beitragen und in der sogenannten Klassifikations-Korrelations-Matrix (KKM) zusammengefasst werden.

4 Ergebnisse

Insgesamt standen nach Beendigung der Datenaufnahme für alle Sportler 164 Versuchsprofile als Lerndaten für das KNN zur Verfügung. Die Lernmethodik für das KNN entsprach dem üblichen Szenario (Splitting der Lerndaten in Training und Testdaten). Das KNN wurde 25 Mal mit zufälliger Datensequenzreihenfolge trainiert. Alle angegebenen Ergebnisse sind Durchschnittswerte dieser 25 Trainingsdurchläufe. Die Diskriminierung erlangt eine Klassifikationsgenauigkeit von 98,8% im Test, d.h. im Mittel werden nur 1.2 von 100 Versuchen nicht korrekt zugeordnet. Die Sensitivität der Klasse MKB beträgt 99.7% und Spezifität 98.6% was der Sen-

sitivität Klasse SMKB entspricht. Damit ergibt sich insgesamt eine hohe Zuverlässigkeit des KNN zur Vorhersage der Kraftbereiche aus den gemessenen Bewegungsprofilen. Die Zusatzinformation des (interpretierbaren) KNN-Modells ist die KKM aller Profilkenngrößen in Bezug zur Klassenunterscheidung, welche in Fig. 2 visualisiert ist. Aus der KKM wird ersichtlich, dass die Mittelwert-Kenngrößen wenig zur Profilunterscheidung beitragen. Größeren Einfluss haben die Kenngrößen Standardabweichung und die Schiefe der Messwerte in der Bewegungstrajektorie. Das Entscheidungsverhalten des KNN kann mit der erlernten Datenprojektion veranschaulicht werden: Die Profile werden so in eine Ebene projiziert, so dass eine maximale Klassentrennbarkeit ersichtlich wird. Diese Visualisierungsmethode ist im Vorteil gegenüber der oft angewendeten Hauptkomponentenanalyse (HKA), welche die Daten nur entsprechend einer Varianzanalyse projektiv darstellt, ohne Bezugnahme zur Trainingsaufgabe (Klassifikation). In Figure 2 sind beide Projektionen gegenübergestellt.

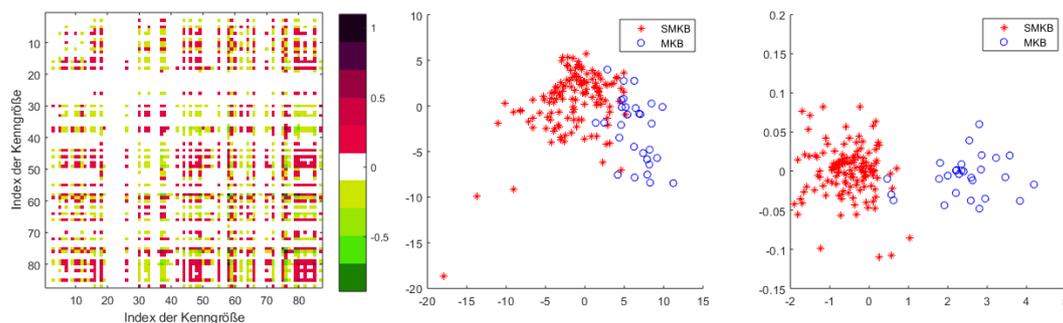


Figure 2: KKM (links), Projektion der Daten in 2D mittels HKA (mitte) und erlernte Datenprojektion mittels GLVQ (rechts)

5 Zusammenfassung

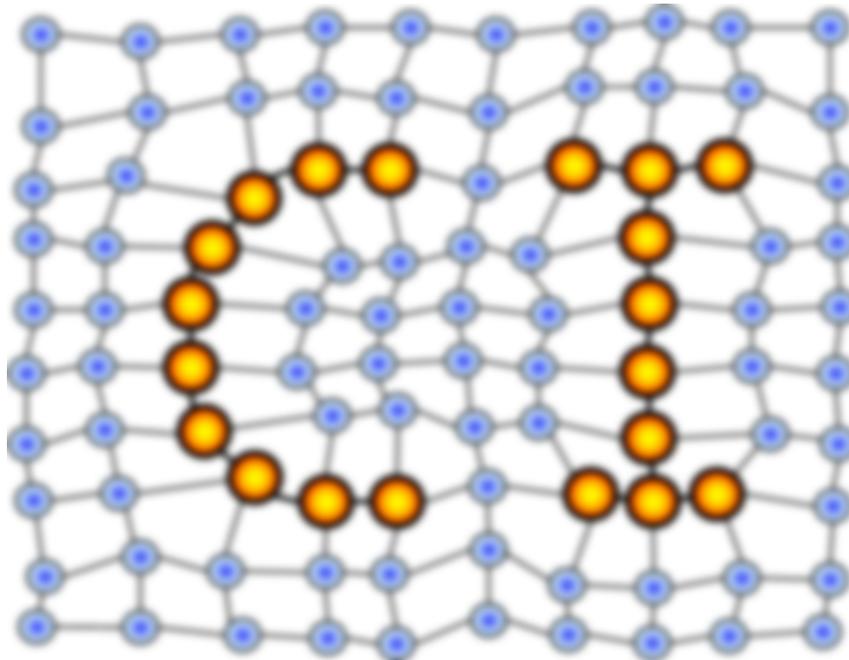
In der vorliegenden Studie wurde der erfolgreiche Einsatz von interpretierbaren KNN als KI-Modell zur Erkennung von Maximalkraftbereichen beim Kniebeugen mit Zusatzgewicht an Hand von biomechanischen/kinematischen Bewegungsprofilen demonstriert. Es wurde gezeigt, dass einerseits eine hohe Klassifikation-Performanz erreicht werden kann. Andererseits lassen die durch das Modell erlernte und bereitgestellte Zusatzinformation weitere Rückschlüsse für den Anwender zu (Bewegungsdynamik, Bewegungspräzision in MKB/SMKB).

References

- [1] Zawieja, M.: Leistungsreserve Hanteltraining. Philippka Sportverlag 2008
- [2] Weineck, J.: Optimales Training. Spitta-Verlag, 2014.
- [3] Ruf, L. , Chéry, C. und Taylor, K.-L.: Validity and reliability of the load-velocity relationship to predict the one repetition maximum in deadlift. *Journal of Strength and Conditioning Research*, 32(3)/681-689, 2018
- [4] Reynolds, J.M., Gordon, T. J, and Robergs, R.A.: Prediction of one Repetition Maximum Strength form multiple prepetion maximum testing and anthropometriy. *Journal of Strength and Conditioning Research*, 20(3), 584-592, 2006
- [5] Brzycki, M.: Strength Testing-Predicting a One-Rep Max from Reps-to-Fatigue. *Journal of Physical Education, Recreation and Dance* 64:1, 88-90, 1993
- [6] Schlumberger A. and Schmidtbleicher D.: Grundlagen der Kraftdiagnostik. In: Banzer W., Pfeifer K., Vogt L. (eds) Funktionsdiagnostik des Bewegungssystems in der Sportmedizin. Springer, Berlin, Heidelberg, 2004
- [7] Hermsdorf, H., Hofmann, N., and Keil, A.: Chapter 16 - Alaska/dynamicus - human movements in interplay with the environment. Academic Press, DHM and Posturography, p. 187-198, 2019
- [8] Kaden, M., Lange, M., Nebel, D., Riedel, M., Geweniger, T., and Villmann, T.: Aspects in Classification Learning - Review of Recent Developments in Learning Vector Quantization. *Foundations of Comp. and Decision Sciences*, 39, 79-105, 2015.
- [9] Rudin, C.: Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nature Machine Intelligence* 1, p206-2018, 2019
- [10] Biehl, M., Hammer, B. und Villmann, T.: Distance Measures for Prototype Based Classification. *BrainComp*, 100-116, 2013.
- [11] Schneider, P., Biehl, M. und Hammer, B.: Adaptive Relevance Matrices in Learning Vector Quantization. *Neural Computation* 21(12): 3532-3561, 2009
- [12] Villmann T., Bohnsack, A. und Kaden, M.: Can Learning Vector Quantization be an Alternative to SVM and Deep Learning? - Recent Trends and Advanced Variants of Learning Vector Quantization for Classification Learning. *Journal of Artificial Intelligence, Soft Computing, Res.* 1, 2018

MACHINE LEARNING REPORTS

Report 01/2020



Impressum

Machine Learning Reports

ISSN: 1865-3960

▽ Publisher/Editors

Prof. Dr. rer. nat. Thomas Villmann
University of Applied Sciences Mittweida
Technikumplatz 17, 09648 Mittweida, Germany
• <http://www.mni.hs-mittweida.de/>

Dr. rer. nat. Frank-Michael Schleif
University of Bielefeld
Universitätsstrasse 21-23, 33615 Bielefeld, Germany
• <http://www.cit-ec.de/tcs/about>

▽ Copyright & Licence

Copyright of the articles remains to the authors.

▽ Acknowledgments

We would like to thank the reviewers for their time and patience.