

Der Einsatz maschinellen Lernens zur inertialen Bewegungsanalyse am Pferderumpf für das digitale Trainingsmonitoring im Leistungssport

Johannes Pavel¹, Christina Fercher² und Frank Herold³

Abstract: Das leistungssportliche Training von Pferd und Reiter ist geprägt durch die langjährige Erfahrung und die individuelle Einschätzung von Reiter und Trainer. Ergänzend dazu soll langfristig eine objektive Möglichkeit zur Beurteilung von Bewegung geschaffen werden. Auf Grund der notwendigen Feldbedingungen der Sportpraxis eignet sich die Verwendung von Inertialsensoren am Pferderumpf [PF05], [NA09], [MA14], [FE17], [WA19]. Ziel dieser Arbeit ist es durch den Einsatz von *Maschinellem Lernen* über neuronalen Netzen die pferdesportpraktischen Bewegungen anhand der inertialen Bewegung des Pferderumpfs zu detektieren. Als Basis dienen die zyklischen Gangarten Schritt, Trab, Linksgalopp und Rechtsgalopp, sowie die Bewegungsrichtung, das Halten und in einem nächsten Schritt die azyklische Springbewegung [DE97], [DE12] und dressurspezifischen Lektionen, um einerseits das tägliche Training im Heimatstall dokumentieren und andererseits eine kinematische Bewegungsanalyse, bspw. am Sprung, durchführen zu können. Dabei beweist die Analyse, dass die verschiedenen Gangarten sehr gut klassifiziert werden können.

Keywords: maschinelles Lernen, neuronales Netz, Long short Term Memory Network, Convolutional Network, Leistungssport, Pferdesport, inertielle Bewegungsanalyse

1 Einleitung

Die Zielsetzung aller beteiligten Personen ist es, talentierte Reiter und Pferde zu fördern, langfristig aufzubauen und über viele Jahre gesund im Spitzensport zu halten. Dabei sind der Ausbau einer systematischen Trainingsstrategie und die Periodisierung der Saisonhöhepunkte mit ausreichenden Regenerationsphasen wichtige Aspekte für die Leistungsfähigkeit sowie Gesunderhaltung der Athleten. Im Pferdesport spielt vor allem das subjektive Empfinden von Reiter und Trainer eine wichtige Rolle. Dabei werden eine allgemeine Saison- und Trainingsplanung, Stärken-Schwächenprofile und Trainingsziele noch nicht fokussiert genug umgesetzt. Bei vielen Pferden ist das Dokumentieren der täglichen Arbeit und Bewegung darüber hinaus mühsam und zeitaufwendig. Eine Trainingsdatenbank existiert bereits, allerdings ist den Athleten der langfristige Mehrwert

¹ Deutsche Reiterliche Vereinigung e.V. (FN), Freiherr-von-Langen-Straße 13, 48231 Warendorf | Universität Kassel, Fachgebiet Verteilte Systeme, Wilhelmshöher Allee 71-73, 34121 Kassel, johannes@uni-kassel.de

² Deutsche Reiterliche Vereinigung | Olympiastützpunkt Westfalen, Dr.-Rau-Allee 32, 48231 Warendorf, c.fercher@osp-waf.de

³ Peiker Cee Consumer Electronics Evolution GmbH, Gartenstraße 25, 61352 Bad Homburg, frank.herold@peiker-cee.de

Betreuer: Harun Baraki, Universität Kassel, Fachgebiet Verteilte Systeme

dieser Arbeit noch nicht ausreichend klar. Aus diesem Grund soll eine einfache und zuverlässige Methode entwickelt werden, welche das Dokumentieren von Trainingsinhalten vereinfacht.

2 Methodik

Um im Grundstein eine große Bewegungsvervielfalt in den Gangarten abbilden zu können, werden sowohl Daten von Spitzenpferden als auch von Freizeitpferden an vier verschiedenen Tagen erfasst. Insgesamt liegen inertielle Bewegungsdaten von 32 unterschiedlichen Pferden (Größe: 130 – 180 cm; Alter: 4 – 23 Jahre) zur Auswertung vor, wobei ein Teil der Pferde an mehreren Messtagen mit unterschiedlichen Bewegungsaufgaben berücksichtigt werden. Das Exterieur, der Ausbildungsstand und auch der disziplinspezifische Verwendungszweck der Pferde ist sehr vielfältig. Den Messungen liegen vier verschiedene Reitbahnen zu Grunde: drei unterschiedliche Reithallen mit den Maßen 20 x 60 m, 70 x 30 m und 20 x 40 m und eine Außenplatz mit den Maßen 65 x 25 m.

Die Anbringung des inertialen Bewegungssensors (*MTw Awinda Motion Tracker XSens*, Niederlande) erfolgt am kaudalen Teil des Brustbeins des Pferdes durch eine mittige Fixierung am Sattelgurt. Mit Hilfe der Software (*MT Manager 2012.1.1 beta*) wird zu Beginn für jedes Pferd in einer ruhenden Position mit einer Ausrichtung entlang einer der langen Seite der Reitbahn ein Reset der Orientierung (Methode: „*Alignment Reset*“) durchgeführt, um das ursprüngliche sensororientierte Koordinatensystem (S), unabhängig der abdominalen Linie oder der Sattelgurtform, per Rotationsmatrizen auf das Objekt Pferd (O) abzustimmen und zusätzlich die Richtung des Weltkoordinatensystems (WKS) auf die Reitbahn (RKS) auszurichten. Damit wird die Ausgangslage und die Vergleichbarkeit der Daten auch für spätere Bewegungsanalysen hergestellt. Abbildung 1 (modifiziert nach FN 2012 & XSens 2016) veranschaulicht die Koordinatensysteme.

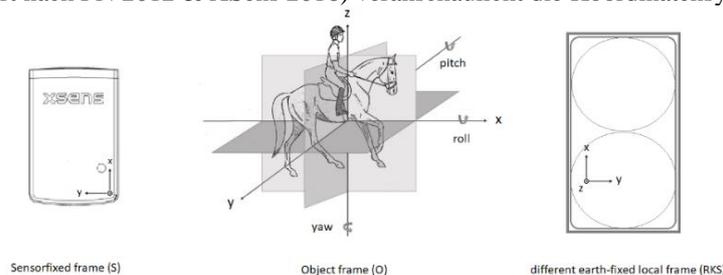


Abb. 1: Ausrichtung der Koordinatensysteme für weitere Bewegungsanalysen

Das Modell des neuronalen Netzes wurde mithilfe von Googles *Framework TensorFlow* erstellt. Dieses Framework stellt diverse Hilfsmittel für den vorgesehenen maschinellen Lernprozess bereit [AB15]. Für diese Arbeit wird die Schnittstelle *Keras* verwendet, um ein komplexes Modell des neuronalen Netzes zu entwickeln. Die Wahl für die vorgesehene Gangartendetektion fällt auf ein Modell, in dem *rekurrente* und

convolutionale, also faltbare, Schichten kombiniert werden. Der convolutionale Teil bereitet dabei die Daten auf und entdeckt neue Merkmale, während der rekurrente Teil für die Klassifizierung einzelner Sequenzen zuständig ist [BR17]. Das Modell des neuronalen Netzes besteht aus insgesamt acht Schichten verschiedener Neuronen. Die erste bildet eine eindimensionale Convolution-Schicht. Durch Reduktion auf eine Dimension ist es möglich die Eigenschaften der ursprünglichen Bildererkennung auf die Klassifizierung von Sensordaten zu übertragen [MI18]. Die zweite und sechste Neuronen Schicht besteht aus Dropout-Neuronen. Diese Neuronenart soll gewährleisten, dass das Neuronale Netz nicht nur für die bereits bekannten Pferde zuverlässige Klassifikationen liefert und setzt aus diesem Grund einen festen Prozentsatz an weitergegebenen Informationen gleich null. Die zweite Neuronen Schicht setzt 50 % der Informationen auf null, die sechste Schicht 40 %. Die dritte Schicht reduziert die Komplexität der vorhergehenden Convolution-Schicht, indem nur Maximalwerte der erlernten Eigenschaften durch eine eindimensionale Max-Pooling-Schicht weiterverwendet werden [CH15]. Die bisherigen Schichten geben jeweils eine zweidimensionale Matrix an die nachfolgenden Schichten des rekurrenten Teils weiter. Für die anschließende Klassifizierung wird allerdings ein eindimensionaler Vektor benötigt. Dieser Vektor wird in der vierten Schicht mithilfe einer *Flatten*-Schicht erzeugt. Die Schichten eins, drei und vier werden von einer *TimeDistributed*-Schicht umschlossen. Diese Schicht ermöglicht es die verwendeten Daten in mehrere Ebenen einzuteilen. Für dieses Neuronale Netz werden jeweils 50 Datensätze in einer Sequenz zusammengefasst und anschließend noch einmal in fünf gleich große Ebenen unterteilt [CH15]. Der Kern des Modells liegt in der rekurrenten Schicht aus *Long Short-Term-Memory-Neuronen* (LSTM). Dabei handelt es sich um die fünfte Schicht des neuronalen Netzes. Diese Schicht zeichnet sich besonders dadurch aus, dass sie in der Lage ist Informationen über lange Zeitabschnitte hinweg zu speichern [HO97]. Die letzten beiden Schichten bestehen aus zwei vollständig verbundenen *Dense*-Schichten. Die erste Dense-Schicht verringert die Komplexität der Ausgabe der vorhergehenden LSTM-Schicht. In der zweiten Dense-Schicht repräsentiert je ein Neuron die Wahrscheinlichkeit der klassifizierten Klasse [CH15]. Für die Aufgabe der Gangartenerkennung gibt es entsprechend der Klassen Halt, Schritt, Trab, Rechtsgalopp und Linksgalopp fünf Neuronen. Für das detektieren der Bewegungsrichtung werden nur drei Klassen benötigt, namentlich Halt, Rechts herum und Links herum. Das Modell des neuronalen Netzes wird zwei Mal unabhängig voneinander mit den unterschiedlichen Aufgaben trainiert und getestet. Dabei entscheidet die unterschiedliche Einteilung der Trainings- und Testdaten über angestrebte Klassifizierungsaufgabe. Für die Gangartenanalyse werden die Daten in die Klassen Halt, Schritt, Trab, Galopp Rechts herum und Galopp links herum eingeteilt, für die Bestimmung der Richtung sind es die Klassen Halt, rechts herum und links herum. Die Trainingsdauer variiert je nach Aufgabe, die Gangartenerkennung benötigt 12 Epochen, die Richtungsklassifizierung benötigt nur die Hälfte der Zeit.

Den Reitern wird lediglich die Gangart und Richtung vorgegeben. Wege, Tempo oder Wendungsgrad (Lektionen) in den entsprechenden Gangarten wurden frei gewählt, um näher am alltäglichen Trainingsablauf zu sein. Die Reiter-Pferd-Paare sind sich vertraut und den einfach gehaltenen Bewegungsaufgaben gewachsen.

Für das neuronale Netz werden die Beschleunigungs-, Drehraten und Magnetfelddaten, sowie die berechneten freien Beschleunigungs- und Lagedaten (Quaternionen) aus den Messungen in 100 Hz berücksichtigt. Ein Drittel der Reiter-Pferd-Paare werden zufällig ausgewählt, von den anderen separiert und stellen fortan den Testdatensatz bereit. Trainings- und Testdatensatz sind dabei disjunkt. Die besondere Architektur des neuronalen Netztes erfordert eine Einteilung der gesammelten Daten in einzelne Sequenzen zu je 50 Datensätzen aufgeteilt, was 0,5 s der Echtzeit entspricht. Pro Datensatz werden 16 Merkmale für das neuronale Netz verwendet (800 Elemente). Durch dieses Verfahren stehen 37.050 Sequenzen für das Training und 10.219 Sequenzen zum Testen des neuronalen Netztes zur Verfügung.

3 Ergebnisse

Für möglichst praxisnahe Ergebnisse wird das neuronale Netz nur über, dem Netz unbekannte, Pferde getestet. Abbildung 2 und Abbildung 3 zeigen die Ergebnisse des Maschinellen Lernvorgangs in Bezug auf die Gangartenerkennung und die Richtungsklassifizierung. Dabei befindet sich auf der Y-Achse die tatsächliche Klasse und auf der X-Achse die vorhergesagte Klasse. Die Zahlen beziffern die Anzahl der klassifizierten Sequenzen Blau sind besonders wenig oder keine Sequenzen in der entsprechenden Klasse, Rot entspricht besonders vielen Sequenzen in den Klassen. Demnach wäre das ideale Ergebnis ein diagonaler, roter Strich von oben links nach unten rechts. Die Fehlerrate steigt mit der Komplexität der gerittenen Aufgabe an. 1200 Sequenzen Halt werden von dem neuronalen Netz korrekt als Halten klassifiziert. 2393 Sequenzen Schritt werden korrekt erkannt, während vier Sequenzen Schritt für Trab, sechs für Rechts- und eine für Linksgalopp erkannt werden. Insgesamt 2330 Sequenzen Trab werden korrekt klassifiziert, während 28 fälschlicherweise als Rechtsgalopp und vier als Linksgalopp detektiert werden. Insgesamt 2126 Sequenzen gehören der Klasse des Rechtsgalopps an, davon werden 15 für Trab und 25 für Linksgalopp gehalten. 2117 Sequenzen Linksgalopp werden korrekt klassifiziert, während vier Mal die Merkmale des Rechtsgalopps und sechs Mal des Trabs überwiegen. Die Genauigkeit der Gangartenanalyse über die verschiedenen Pferde liegt bei über 99 % mit einer allgemeinen Fehlerrate von unter 1 %. Die Fehlerrate variiert pro Pferd und Lektion, so ist im Laufe der Evaluation das Pferd Nummer 18 mit einer ungleich höheren Fehlerrate im Linksgalopp aufgefallen. Es handelt sich hierbei um ein Springpferd, welches gerade im Linksgalopp sichtbar schief galoppiert. Die Fehlerrate bei diesem Pferd und der Aufgabe liegt bei etwa 7 %.

Das Ergebnis der Klasse Halt zeigt sich ähnlich ideal wie bei der Gangartenunterscheidung, lediglich 2 Sequenzen werden als links herum erkannt. Allerdings ist die Unterscheidung von rechts und links deutlich fehleranfälliger. Von 4501 Sequenzen auf der linken „Hand“ wurden insgesamt 595 fälschlicherweise für rechts herum gehalten und eine wurde als Halt klassifiziert. 4034 Sequenzen werden korrekt als geritten der rechten „Hand“ detektiert, während 484 Sequenzen als links herum erkannt

werden. Insgesamt liegt die Genauigkeit der Unterscheidung von rechts und links liegt bei etwa 89 %.

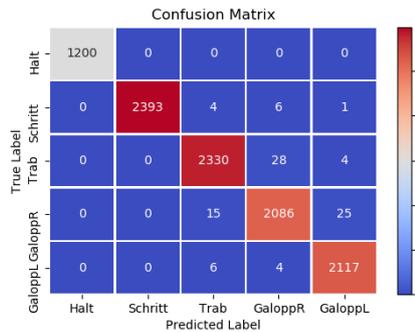


Abb. 3: Ergebnis der Gangarterkennung

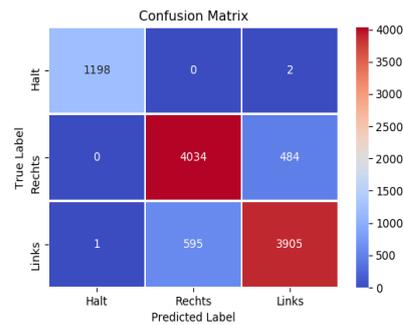


Abb.4: Ergebnis der Richtungsanalyse

4 Diskussion

Die Ergebnisse des maschinellen Lernverfahrens haben gezeigt, dass es möglich ist die Bewegungen von Pferden mit unterschiedlichen Bewegungsamplituden anhand bekannter IMU Daten sehr gut zu klassifizieren. Dennoch lassen sich zwei mögliche Fehlerquellen festhalten. Durch die Vielfalt der Pferde, deren Exterieur und Ausbildungsstand, zeigen sich auch sportpraktisch bekannte Probleme. Der Takt, als räumliches und zeitliches Gleichmaß der Bewegung, bildet den Grundstein der Ausbildung. Ungleichheiten im Rhythmus der Fußfolge, bspw. durch mangelnden Durchsprung im Galopp, Schiefe im Bewegungsablauf oder fehlender Losgelassenheit im Schritt, zeigen sich als solche auch in den Daten und bilden die Ausreißer in der Gangarterkennung über 1 %. Mit einer wachsenden Datenbasis und weiterem Training des neuronalen Netzes werden diese weiter minimiert. Dennoch sind Störungen und „Grenzgänger“ in der Sportpraxis vorhanden und sollten bei starken Abweichungen von Normen möglicherweise objektiv als solche aufgezeigt werden. Die zuverlässige Detektion der gerittenen Reitrichtung stellt dabei eine weitaus größere Herausforderung dar. Die Zeitabschnitte, in welchen sich die Pferde auf einer geraden Linie, also entlang der langen oder kurzen Seite, bewegen, lassen sich nur sehr schwer in eine bestimmte Richtung einordnen. Hierzu wird ein weiteres Messprojekt durchgeführt, in welchem die Kategorie gerade ergänzt wird. Damit wird nicht nur die Fehlerrate minimiert, sondern zusätzlich in Summe die gerittenen Handwechsel erfasst. Da die Aufteilung einer Trainingseinheit in linke und rechte „Hand“ üblich ist, sollte für eine Auswertung die Zuordnung von gerade ohne Handwechsel dennoch nach links und rechts erfolgen.

5 Literatur

- [AB15] Abadi, M. et al. (2015). Tensorflow. Zugegriffen am 15.03.2020 unter: <https://www.tensorflow.org/>
- [BR17] Brownlee, J. (2017). CNN Long Short-Term Memory Networks. Zugegriffen am 12.03.2020 unter: <https://machinelearningmastery.com/cnn-long-short-term-memory-networks/>
- [CH15] Chollet, F. et al. (2015). Keras Documentation. Zugegriffen am 13.03.2020 unter: <https://www.keras.io/>
- [DE12] Deutsche Reiterliche Vereinigung e.V. (Hrsg.). (2012). *Grundausbildung für Reiter und Pferd*. (Richtlinien für Reiten und Fahren, Bd. 1). (29. Auflage). Warendorf: FN Verlag.
- [DE97] Deutsche Reiterliche Vereinigung e.V. (Hrsg.). (1997). *Ausbildung für Fortgeschrittene*. (Richtlinien für Reiten und Fahren, Bd. 2). (13. Auflage, Nachdruck 2010). Warendorf: FN Verlag.
- [FE17] Fercher, C. (2017). Erfassung leistungsrelevanter Parameter mit Inertialsensoren zur Darstellung der Springbewegung von Sportpferden. *Pferdeheilkunde – Equine Medicine* 33(4), 377-385.
- [HO97] Hochreiter, S., Schmidhuber, J. (1997). Long Short-term Memory. *Neural Computation (journal)*, vol. 9, issue 8, S.1735-1780
- [MA14] Martin, P., Chateau, H., Pourcelot, P., Duray, L. & Cheze, L. (2014). Comparison Between Inertial Sensors and Motion Capture System to Quantify Flexion-Extension Motion in the Back of a Horse. *Equine Vet J* 46(46), 43.
- [MI18] Missinglink (Hrsg.). (2018) Convolutional Neural Network: How to Build One in Keras & PyTorch. Zugegriffen am 14.03.2020 unter: <https://missinglink.ai/guides/neural-network-concepts/convolutional-neural-network-build-one-keras-pytorch/>
- [NA08] Nankervis, K., Hodgins, D. & Marlin, D. (2008). Comparison between a sensor (3D accelerometer) and ProReflex motion capture systems to measure stride frequency of horses on a treadmill. *Comp. Exercise Physiol.* 5(3-4), 107-109.
- [PF05] Pfau T., Witte T. H., Wilson A. M. (2005) A method for deriving displacement data during cyclical movement using an inertial sensor. *J. Experim. Biol.* 208, 2503-2514.
- [WA19] Warschun, F., Fercher, C., Schleichardt, A. & Ueberschär, O. (2019). Reliabilität von XSens MTw Awinda Motion Trackern im Springreiten. In: Arampatzis, A., Braun, S., Schmitt, K. & Wolfahrt, B. (Hrsg.): *Sport im öffentlichen Raum. 24. dvs-Hochschultag Berlin 18.-20. September 2019 Abstracts*. Schriften der Deutschen Vereinigung für Sportwissenschaft. Vol 282. Hamburg: Feldhaus: 54.
- [XS16] XSens (Hrsg.). (2016). MTW Awinda User Manual. Zugeriffen am 11.09.2019 unter: https://www.xsens.com/hubfs/Downloads/Manuals/MTw_Awinda_User_Manual.pdf