

Vergleich von Möglichkeiten zur computergestützten Analyse von Körperhaltungen für Ergonomieverfahren

Edgar SCHERSTJANOI, Daniel GRÖLLICH, Martin SCHMAUDER

*Professur für Arbeitswissenschaft,
Technische Universität Dresden
Marschnerstraße 39, D-01307 Dresden*

Kurzfassung: In der Anwendung von ergonomischen Screeningverfahren steigt der Bedarf von computergestützten Umsetzungen. Die meisten Implementierungen nutzen zur Klassifikation der Körperhaltung festgelegte Schwellwerte für Gelenkwinkel oder Distanzen und berechnen somit die Ausprägung bestimmter Einflussgrößen. Die darin typische, grobe Einschätzung und das Erfahrungswissen eines Beobachters können damit jedoch nicht umgesetzt werden. Methoden des maschinellen Lernens stellen sich der Herausforderung, Wissen zu modellieren und können ebenso für eine Klassifikation von menschlicher Körperhaltung genutzt werden. Dieser Beitrag widmet sich dem Vergleich verschiedener computergestützter Methoden, mit dem Ziel Vorteile und Herausforderungen bei der Modellierung von ergonomischem Wissen identifizieren zu können.

Schlüsselwörter: Screeningverfahren, Ergonomie, Körperhaltung, maschinelles Lernen, Leitmerkmalmethode

1. Einleitung

Ergonomische Verfahren wie die Leitmerkmalmethoden der BAuA [LMM] (Jürgens et al. 2001), Rapid Upper Limb Assessment [RULA] (McAtamney & Corlett 1993) oder Ovako Working Posture Analysis [OWAS] (Karhu et al. 1977) beinhalten die Einschätzung einer Körperhaltung während einer Arbeitstätigkeit. Teilweise stehen diese und andere Ergonomieverfahren auch als Softwarelösung zur Verfügung. Zur automatisierten Verarbeitung von Körperhaltungen werden dann häufig Schwellwerte von Gelenkwinkeln oder Abstände zwischen Körperteilen verwendet, um entsprechende Klassifikationen vornehmen zu können. Dadurch entsteht allerdings auch eine Diskrepanz zwischen auf Erfahrung basierendem Expertenwissen und formalen Regeln für eine automatisierte Verarbeitung. Es liegt die Vermutung nahe, dass Zusammenhänge, die implizit im Wissen bei der Beurteilung einer Körperhaltung enthalten sind, nicht durch eine Menge an formellen Regeln vollständig abgebildet werden können.

Der rasante Anstieg heute zur Verfügung stehender alternativer Herangehensweisen der Signal- und Datenverarbeitung, wie beispielsweise künstliche neuronale Netze [KNN] zur Erzeugung einer künstlichen Intelligenz [KI], motivieren dazu, das genannte Problem zu lösen. Methoden des überwachten maschinellen Lernens ermöglichen es, das Expertenwissen so zu modellieren, dass nicht einzelne Regeln, sondern gewichtete Verbindungen von Übertragungs- und Aktivierungsfunktionen zur automatisierten Klassifikation einer aufgenommenen Körperhaltung führen. Somit bleibt das implizite Expertenwissen im automatisierten Klassifikationsprozess einer Körperhaltung erhalten.

2. Screeningverfahren für ergonomische Analysen

Viele Verfahren zur Bewertung von Arbeitsplätzen beziehen sich, neben beispielsweise Umgebungsfaktoren, räumlichen Bedingungen oder Einflüssen durch Arbeitsobjekte, vor allem auf eine Analyse der dazugehörigen Arbeitsbewegung. Dabei spielen Körperhaltungen eine bedeutende Rolle.

Verfahren, die keine detaillierte Einschätzung von Einflussgrößen benötigen, sondern möglichst schnell und kompakt eine hohe physische Belastung und dadurch gesundheitsgefährdende Risiken identifizieren sollen, werden als Screeningverfahren verstanden (Börner et al. 2017). Darin werden Körperhaltungen meist unter Teilaspekten, wie z.B. Armstellung, Rumpfhaltung sowie Hand- oder Beinstellungen, eingeordnet. Mögliche Klassifizierungen umfassen darin die Einordnungen, wie z.B. "starke Neigung", "geringe Drehung" (LMM) oder ">30°, <90°" (RULA). Im Ergebnis der einzelnen relevanten Faktoren entstehen bspw. farblich kodierte Risikofaktoren als Richtwert für einen resultierenden Handlungsbedarf.

Unabhängig dessen, wie diese Kategorien formuliert werden, ist der Zweck darin zu finden, Beobachtern möglichst schnell und genau eine Entscheidungsgrundlage zu bieten, ohne dass dabei auf detailliertes medizinisches Expertenwissen zurückgegriffen werden muss, obgleich die Grundlage von bspw. Winkelangaben auf eben solche zurückzuführen ist. (z.B. in Schüldt et al. 1987 oder Tichauer, 1966)

In diesem Zusammenhang stellt sich die Frage, inwiefern Beobachter dazu in der Lage sind, Gelenkwinkel oder Distanzen genau abschätzen zu können, vor allem, wenn die betreffende Körperhaltung aus einer Kombination verschiedener Drehungen und Abspreizungen besteht.

3. Computergestützte Methoden zur Klassifikation der Körperhaltung

Durch die Verwendung computergestützter Methoden werden Bewertungsprozesse mess- und reproduzierbar. Es können solche Parameter gekennzeichnet werden, die einen besonders hohen Anteil am resultierenden Risikofaktor aufweisen. Der Handlungsbedarf kann in virtuellen Umgebungen umgesetzt und auch dessen Auswirkungen überprüft werden.

Um computergestützt eine Körperhaltung zu analysieren, ist es naheliegend, die Körperbewegung digital so zu verarbeiten, dass eine Hierarchie aus Gelenkpunkten als Skelettstruktur zur Verfügung steht. Üblicherweise stehen dazu digitale Menschmodelle [DMM] bereit, die in CAD-Umgebungen einer virtuellen Arbeitsumgebung hinzugefügt werden können, um bspw. prototypische Untersuchungen an Arbeitsgegenständen oder in einer virtuellen Arbeitsumgebung durchführen zu können. Neben der Möglichkeit Körperhaltungen und Bewegungen händisch zu parametrisieren, sind in Analysesoftwaretools oftmals auch Schnittstellen zu Aufnahmesystemen vorhanden, um menschliche Bewegungen direkt aufzunehmen. Neben optischen Aufnahmetechnologien (z.B. OptiTrack, MS Kinect oder OpenPose in Cao et al. 2018) steigt auch die Verwendung von Inertialsensoren, da damit kameratypische Probleme, wie Verdeckung, Reichweite oder Belichtung umgangen werden können. Motion Capture Systeme, die auf Inertialsensoren basieren, messen an bestimmten Körperpunkten Winkelbeschleunigungen und können somit Rückschlüsse zur Körperbewegung berechnen.

Gerade Verfahren wie RULA erwecken den Anschein besonders geeignet für eine computergestützte Verarbeitung zu sein, da Körperhaltungen durch Schwellwerte in

Gelenkwinkeln definiert sind und somit auch einfach berechnet werden können. Aber auch Verfahren wie LMM wurden bereits in DMM-Umgebungen umgesetzt. Darin stellte es sich als Herausforderung dar, Symbole und Beschreibungen zur Körperhaltung in formale Werte zu überführen. Eine solche Implementierung ist beispielsweise in Kamusella et al. (2016) zu finden.

4. Maschinelles Lernen zur Klassifikation von LMM-Körperhaltungen

Im Rahmen der hier vorgestellten Studie wurde mittels eines Motion Capture Systems (XSens) ein Datensatz von verschiedenen Körperhaltungen generiert. Dieser kann dazu verwendet werden, durch maschinelles Lernen ein spezifisches Modell zu erstellen, welches wiederum ein künstliches neuronales Netz befähigt Entscheidungen zur Bewertung von Körperhaltungen zu treffen.

Für den Datensatz wurden 34 Arbeitshaltungen frei gewählt, die von einer Person eingenommen wurden. Jede Körperhaltung wurde während der Aufnahme für mindestens 30 Sekunden statisch beibehalten. Im Ergebnis entstand ein Datensatz mit 34 Körperhaltungen zu je mindestens 900 Frames, welche wiederum für 23 Körpergelenkpunkte Informationen zur Gelenkrotation und -position beinhalten. Ein strukturelles Beispiel zu dieser Informationsmenge ist Tabelle 1 zu entnehmen.

Tabelle 1: Auszug des Datensatzes zu einer Körperhaltung. Für jeden Frame (F#) ist zu einer Zeitangabe (T) die räumliche Information zu jedem der 23 Gelenkpunkte (V0 – V23) in Form von Rotations- (ROT als Quaternion) oder Positionsinformation (POS in 3D Raumposition) enthalten. Jede Körperhaltung beinhaltet mindestens 900 Frames. In diesem Fall 1577.



F#	T	V0 ROT	V0 POS	V1 ROT	V1 POS	...	V23 ROT	V23 POS
1	2:44:359	1.36989, 1.09962, 1.03113, 0.7595	-0.04293, -0.06278, -0.6460	1.36551, 1.11577, 1.14037, 0.757934	0.00457, -0.01182, -0.6522	...	1.60197, 0.9697, 0.02011, 0.83943	0.00175, 0.00825, -0.54338
...
1577	2:48:125	1.3242, 1.11287, 0.9433, 0.3245	0.01413, -0.01798, -0.5250	1.32251, 1.8977, 1.24084, 0.52764	0.02447, -0.00812, -0.22532	...	1.52797, 0.8937, 0.0551, 0.83522	0.00152, 0.00625, -0.47788

Zwei weitere Personen, die über geschultes ergonomisches Fachwissen verfügen, bewerteten während der Aufnahme jede der 34 eingenommenen Körperhaltungen bezüglich Oberkörperdrehung (OKD), Oberkörperneigung (OKN), Lastposition (LAK), Hocken/Knien (HOK) und eingeschränkter Haltungsstabilität (HST). Diese 5 Kriterien sind der LMM entnommen, obgleich es darin keine explizite Unterteilung dazu gibt. Der Wertebereich erstreckt sich für den Rahmen dieser Untersuchung in folgende Ausprägungen:

- OKD – keine (0), gering verdreht (1), stark verdreht (2)
- OKN – aufrecht (0), gering geneigt (1), weit geneigt/ tief gebeugt (2)
- LAK – am Körper (0), körpernah (1), körperfern (2)
- HOK – ja (1), nein (0)
- HST – ja (1), nein (0)

Tabelle 2 enthält Auszüge zu den Bewertungen der Beobachter entsprechend der genannten Aspekte zur Körperhaltung (KHA). Es ist erkennbar, dass sich einerseits die Meinungen leicht unterscheiden, beispielsweise bezüglich der Haltungsstabilität bei Körperhaltung 7 (KH7). Andererseits sind bei manchen Körperhaltungen (bspw. KH30) die Einschätzungen identisch.

Tabelle 2: Auszug des Datensatzes zu einer Körperhaltung. Für jeden Frame (F#) ist zu einer Zeitangabe (t) die räumliche Information zu jedem der 23 Gelenkpunkte (V0 – V23) in Form von Rotations- (ROT als Quaternion) oder Positionsinformation (POS in 3D Raumposition) enthalten. Jede Körperhaltung beinhaltet mindestens 900 Frames.

KH7	KHA	E1	E2	KH30	KHA	E1	E2
	OKD	1	1		OKD	0	0
	OKN	0	1		OKN	0	0
	LAK	2	2		LAK	2	2
	HOK	1	1		HOK	0	0
	HST	1	0		HST	1	1

Ein Teil dieses Datensatzes, die Menge von 28 Körperhaltungen - inklusive der Einschätzung der Beobachter - bilden die Trainingsmenge für die Anwendung des maschinellen Lernens. Ein künstliches Neuronales Netz nutzt dieses Wissen und gewichtet solche Verbindungen, die zu entsprechenden Rückschlüssen führen. Das Ziel besteht anschließend darin solche Körperhaltungen zu klassifizieren, die nicht Bestandteil der Trainingsmenge sind: die übrigen 6 Körperhaltungen werden zur Validierung des trainierten Modells verwendet.

5. Auswertung

Neben den Entscheidungen der KI, wurden den Beobachtern die Körperhaltungen erneut (mit einem zeitlichen Versatz von etwa einer Woche) in zwei Varianten zur Bewertung vorgelegt: 1. in Form eines Fragebogens, der zur jeweiligen Körperhaltung nur ein einzelnes Foto beinhaltet und 2. als bewegliche 3D Darstellung des Skeletts in einer CAD Umgebung. Abbildung 1 und 2 zeigen beispielhaft das Foto und zwei Perspektiven der Skelettdarstellung von zwei ausgewählten Körperhaltungen (KH).




Abbildung 1: Foto und zwei Perspektiven der 3D-Skelettdarstellung von KH28. Mit einem Bein kniend, das andere Bein weit abgespreizt, bei weiter Entfernung des Lastobjektes zum Körper.



Abbildung 2: Foto und zwei Perspektiven der 3D-Skelettdarstellung von KH32. Stabile, aufrechte Haltung bei leichter Oberkörperdrehung.

Des Weiteren wurde der Berechnungsvorschlag mittels DMM (CharAT Ergonomics) aus Kamusella et al. (2016) implementiert und dem Vergleich hinzugefügt. Weiterhin wurde eine Übersicht für alle im Experiment eingenommenen Validierungskörperhaltungen erstellt, die die Einschätzung der beiden Beobachter (E1, E2) nach folgendem Schema enthält:

- Bewertung jeweils während der tatsächlichen Ausübung (E1R bzw. E2R),
- Retrospektive Bewertung anhand des aufgenommenen Fotos (E1F bzw. E2F) und
- Retrospektive Bewertung mittels 3D-Skelettdarstellung (E1V bzw. E2V).

Diese Bewertungen stehen den Ergebnissen der künstlichen Intelligenz gegenüber, die entsteht, wenn für das maschinelle Lernen das Wissen der jeweiligen Beobachter genutzt wurde (ML1 bzw. ML2). In Tabelle 1 und 2 sind die Ergebnisse dargestellt. Tabelle 1 bezieht sich auf KH28 (dargestellt in Abbildung 1), Tabelle 2 auf KH32 (dargestellt in Abbildung 2).

Tabelle 3: Bewertung zu Körperhaltung 28 der beiden Beobachter (E1- bzw. E2-) jeweils während der Beobachtung (-R), per Fotoanalyse (-F) und als 3D Skelettdarstellung in CAD (-V). DMM zeigt die Bewertungen der Implementierung aus Kamusella et al. 2016.. ML1 bzw. ML2 weist die Ergebnisse des maschinellen Lernens des Wissens von Beobachter 1 und 2 aus.

	E1R	E1V	E1F	ML1	E2R	E2V	E2F	ML2	DMM
OKD	2	1	1	1	2	2	1	1	1
OKN	2	1	2	1	2	2	2	1	0
LAK	2	2	2	2	2	2	2	2	2
HOK	0	1	1	1	1	1	1	1	1
HST	1	1	1	0	1	1	1	0	0

Tabelle 4: Bewertungen zu Körperhaltung 32 nach gleichem Prinzip wie Tabelle 3.

	E1R	E1V	E1F	ML1	E2R	E2V	E2F	ML2	DHM
OKD	1	1	0	1	1	1	1	1	1
OKN	0	0	0	0	0	0	0	0	0
LAK	1	1	1	1	0	0	1	0	1
HOK	0	0	0	0	0	0	0	0	0
HST	0	0	0	0	0	0	0	0	0

Bei Analyse der Ergebnisse werden mehrere Diskussionspunkte deutlich. Zum einen führen die unterschiedlichen manuellen Bewertungsverfahren (Einschätzung der KH während der Aufnahme, per Foto und als 3D-Skelettdarstellung) teilweise zu unterschiedlichen Ergebnissen. Mit einem einzelnen Foto sind durch Perspektive oder Verdeckung nicht alle relevanten Details einsehbar. Bei der Skelettdarstellung kann zwar die Position der virtuellen Kamera eingestellt werden, allerdings ist durch fehlende Körperhülle, Bekleidung oder die konkrete Ausprägung des Lastobjektes ebenso der Informationsraum stark eingeschränkt. Die Ergebnisse des maschinellen Lernens folgen grob dem Einschätzungsstil des jeweiligen Beobachters, variieren jedoch ebenso und führen nicht zum gleichen Ergebnis, wie die DMM Methode, bei der Schwellwerte und Distanzen als Kriterium für die Einschätzung verwendet werden. Allerdings entspricht auch DMM nicht eindeutig den Einschätzungen der Beobachter, was wiederum die These unterstützt, dass formale Regeln nicht förderlich sind, sollte das Wissen von Experten modelliert werden.

6. Ausblick

Maschinelles Lernen und die Verwendung von KNN kann zur Bewertung von Körperhaltungen verwendet werden. Da der Trainingsdatensatz mit 34 Körperhaltungen nur einen Bruchteil möglicher Arbeitsszenarien abdeckt ist davon auszugehen, dass eine umfangreichere Datenmenge auch zu besseren Ergebnissen führen kann. Ebenso bieten sich umfangreiche Möglichkeiten zur Optimierung des KNN.

Ein angepasster, optimierter trainierter Datensatz kann in vielen computergestützten Anwendungen verwendet werden. Solange für die verschiedenen Skeletthierarchien entsprechende Überföhrungsfunktionen implementiert werden, führt die Eingangsinformation – die aufgenommene Körperhaltung - zu der gesuchten Klassifikation.

7. Literatur

- Börner, K., Löffler, T., & Bullinger-Hoffmann, A. C. (2017). CheckAge-Screening-Verfahren für die Bewertung alter(n)sgerechter Arbeitsplätze. *aw&I Report*, 2, 51-51.
- Cao, Z., Hidalgo, G., Simon, T., Wei, S. E., & Sheikh, Y. (2018). OpenPose: realtime multi-person 2D pose estimation using Part Affinity Fields
- Jürgens, W. W., Mohr, D., Pangert, R., Pernack, E., Schultz, K., & Steinberg, U. (2001). Handlungsanleitung zur Beurteilung der Arbeitsbedingungen beim Heben und Tragen von Lasten. *LASI Veröffentlichung*, 9.
- Kamusella, C., Scherstjanoi, E., & Schmauder, M. (2016). Lösungsansatz zur ergonomischen Bewertung von Last-und Kraftausübungsfällen unter Nutzung eines digitalen Menschmodells. *Zeitschrift für Arbeitswissenschaft*, 70(2), 99-107.
- Karhu, O., Kansil, P., & Kuorinka, I. (1977). Correcting working postures in industry: a practical method for analysis. *Applied ergonomics*, 8(4), 199-201.
- McAtamney, L., & Corlett, E. N. (1993). RULA: a survey method for the investigation of work-related upper limb disorders. *Applied ergonomics*, 24(2), 91-99.
- Schüldt, K., Ekholm, J., Harms-Ringdahl, K., Arborelius, U. P., & Németh, G. (1987). Influence of sitting postures on neck and shoulder emg during arm-hand work movements. *Clinical Biomechanics*, 2(3), 126-139.
- Tichauer, E. R. (1966). Some aspects of stress on forearm and hand in industry. *Journal of Occupational and Environmental Medicine*, 8(2), 63-71.



Gesellschaft für
Arbeitswissenschaft e.V.

Digitale Arbeit, digitaler Wandel, digitaler Mensch?

66. Kongress der
Gesellschaft für Arbeitswissenschaft

TU Berlin
Fachgebiet Mensch-Maschine-Systeme

HU Berlin
Professur Ingenieurpsychologie

16. – 18. März 2020, Berlin

GfA-Press

Bericht zum 66. Arbeitswissenschaftlichen Kongress vom 16. – 18. März 2020

**TU Berlin, Fachgebiet Mensch-Maschine-Systeme
HU Berlin, Professur Ingenieurpsychologie**

Herausgegeben von der Gesellschaft für Arbeitswissenschaft e.V.
Dortmund: GfA-Press, 2020
ISBN 978-3-936804-27-0

NE: Gesellschaft für Arbeitswissenschaft: Jahresdokumentation

Als Manuskript zusammengestellt. Diese Jahresdokumentation ist nur in der Geschäftsstelle erhältlich.
Alle Rechte vorbehalten.

© **GfA-Press, Dortmund**
Schriftleitung: Matthias Jäger

im Auftrag der Gesellschaft für Arbeitswissenschaft e.V.

Ohne ausdrückliche Genehmigung der Gesellschaft für Arbeitswissenschaft e.V. ist es nicht gestattet:

- den Kongressband oder Teile daraus in irgendeiner Form (durch Fotokopie, Mikrofilm oder ein anderes Verfahren) zu vervielfältigen,
- den Kongressband oder Teile daraus in Print- und/oder Nonprint-Medien (Webseiten, Blog, Social Media) zu verbreiten.

Die Verantwortung für die Inhalte der Beiträge tragen alleine die jeweiligen Verfasser; die GfA haftet nicht für die weitere Verwendung der darin enthaltenen Angaben.

Screen design und Umsetzung

© 2020 fröse multimedia, Frank Fröse

office@internetkundenservice.de · www.internetkundenservice.de