# Exposé für die Bachelorarbeit: Segmentierung von Aktivitätsdaten mit ClaSP

von Sunita Singh Betreuer: Ulf Leser Betreuer: Arik Ermshaus

Institution: Institut für Informatik, Humboldt Universität zu Berlin

21. Februar 2022

Abstract Es gibt verschiedenste Sensorarten, die in der Lage sind, Daten aufzunehmen. So können Sensoren etwa extern angebracht sein, wie es bei Kameras der Fall ist, oder tragbar in einer Smartwatch verbaut sein. Für die Erkennung menschlichen Aktivitäten, also im Forschungsfeld der Human Activity Recognition (HAR), sind insbesondere die tragbaren Sensoren interessant. Die gesammelten Daten können als Zeitreihe dargestellt werden, um verschiedene Aktivitätsprozesse oder besondere Vorkommen (z.B. einen Sturz) automatisch zu erkennen, weil der Wechsel von einer Aktivität zu einer anderen üblicherweise zu einer deutlichen Änderung des aufgenommenen Signals führt. Die Zeitreihensegmentierung ist ein Gebiet der Zeitreihenanalyse, das sich mit dem Problem befasst, die Änderungspunkte in Zeitreihen zu erkennen, wobei in dieser Arbeit ein besonderes Augenmerk auf den Segmentierungsalogorithmus ClaSP gelegt wird. Ferner werden auch andere Arbeiten zur Segmentierung von Zeitreihen beleuchtet. Wichtig um die Performance der Algorithmen zu überprüfen, ist ein diverser und großer Datensatz. Aus diesem Grund ist das Ziel der Arbeit einen neuen Datensatz von Zeitreihen aufzunehmen und die Segmentierungsmethoden damit zu evaluieren.

## 1 Einführung

Heutzutage sind kleine, leistungsstarke Geräte wie z.B. Smartphones oder Smartwatches für viele Menschen ein wichtiger Bestandteil des alltäglichen Lebens. Mit diesen Geräten ist es mittels Sensoren möglich, Daten im Alltag zu sammeln. Solche Daten können neben tragbaren Sensoren auch von externen Sensoren, wie zum Beispiel durch Kameras, aufgenommen werden. Es gibt dabei eine Vielzahl an Sensorentypen wie beispielsweise Beschleunigungssensoren, Mikrofone, Herzfrequenz-Sensoren und Lautstärke-Sensoren [5].

Human Activity Recognition (HAR) ist ein Forschungsfeld, welches sich solche Daten zu Nutze macht, um zu erkennen, welche Aktivitäten von einer Person zu einer gegebenen Zeit ausgeführt wurden oder aktuell werden. Dies ist besonders interessant für medizinische, militärische und sicherheitsrelevante Anwendungen. Beispielsweise müssen Patienten mit Übergewicht, Herzproblemen oder Diabetes als Teil ihrer Behandlung bestimmten Bewegungsplänen folgen [5]. Mit HAR ist es nun möglich, dem behandelnden Arzt Feedback über das Verhalten der Patienten zu geben [5].

Eine Auflistung an Aktivitäten, die von HAR Systemen erkannt werden können, ist in Tabelle 1 zusehen. In Abbildungen 1 sind acht Fitnessübungen zu sehen, die Teil eines Bewegungsplan sein könnten. Beispielsweise könnte der Plan eines Patienten wie folgt aussehen: push-up (30sek) - sit-up (30sek) - squat (30sek). Die Daten können auf unterschiedliche Weise mit verschiedenen Sensoren aufgenommen werden. In [2] wird z.B. ein Handy zu einem Sonarsensor umfunktioniert, indem durch die Smartphone-Lautsprecher ein kontinuierliches 20 kHz Signal ausgesendet wird. Das Smartphone-Mikrofon wird verwendet, um das Echosignal zu empfangen, welches durch die Körperbewegungen ensteht. Ein weiteres Beispiel, um Bewegunsabläufe aufzunehmen, wird in Abbildung 2 deutlich. Dort wurden die Messungen mit einem Beschleunigungssensor erfasst.

Die aufgenommenen Daten kann man als eine sogenannte Zeitreihe interpretieren, wobei es sich um eine zeitliche Abfolge von Messwerten handelt. Um nun zu erkennen, wann und wie lange welche Aktivität tatsächlich ausgeführt wurde, muss die Zeitreihe segmentiert werden. Die Aufteilung der Zeitreihe in Segmente, nennt man auch Zeitreihensegmentierung (kurz TSS für "time series segmentation") [7]. Für die Segmentierung von Zeitreihen gibt es einige Algorithmen, die in dieser Arbeit näher betrachtet werden, wobei ClaSP (Classification Score Profile) [7] ein Segmentierungsalgorithmus ist, der hier besonders im Fokus steht. Die grundsätzliche Vorangehensweise der TSS Algorithmen ist, die Segmente an genau den Punkten aufzuteilen, die auf eine Änderung im zugrunde liegenden Verhalten hinweisen.

## 2 Zielstellung

Das Ziel dieser Arbeit ist es einen neuen Human Activity Datensatz aufzunehmen, aufzubreiten und den ClaSP Algorithmus sowie zwei weitere Segmentierungsalgorithmen mit dem neuen Datenset im Hinblick auf ihre Genauigkeit zu evaluieren. Am Ende der Arbeit soll folgende Frage geklärt werden: Kann ClaSP Human Activity Daten genauer segmentieren als andere Algorithmen?

Gruppe	Aktivitäten	
Bewegung	Gehen, Rennen, Sitzen, Stehen, Liegen, Trep-	
	pen hinausteigen, Treppe hinabsteigen, Roll-	
	treppe fahren und Fahrstuhl fahren.	
Verkehrsmittel	Busfahren, Fahrradfahren und Auofahren.	
Telefonnutzung	Textnachrichten schreiben, Telefonieren.	
Tägliche	Essen, Trinken, Arbeiten am PC, Fernsehen,	
Aktivitäten	Lesen, Zähneputzen, Dehnen, Schrubben und	
	Staubsaugen.	
Fitness	Rudern, Gewichte heben, Spinning, Nordic	
	Walking und Liegestütze machen.	
Militär	Krabbeln, Knien und Öffnen einer Tür.	
Oberkörper	Kauen, Sprechen, Schlucken, Seufzen und Be-	
	wegen des Kopfes.	

Tabelle 1: Von HAR Systemen zu erkennende Aktivitäten [5]

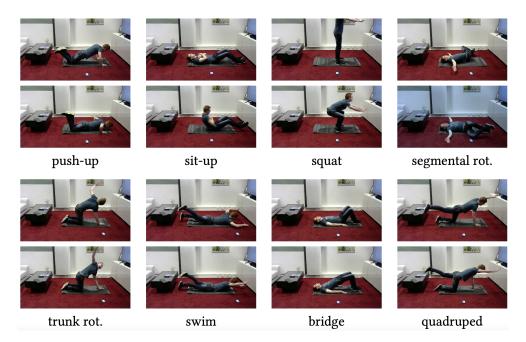


Abbildung 1: Acht Fitnessübungen mit der jeweiligen Sensorposition [2]

# 3 Grundlagen und verwandte Arbeiten

#### Grundlagen

- 1. Wir gehen wie [7] davon aus, dass ein *physischer Prozess* diskrete Zustände hat, dessen Wechsel zu Änderungen in den Messwerten von observierenden Sensoren führen..
- 2. Ein wichtiger Sensor in HAR ist das *Gyroskop*, auch Kreiselinstrument genannt. Diese Art von Sensoren misst die Winkelgeschwindigkeit, d.h. die Änderung des Rotationswinkel je Zeiteinheit.
- 3. Der Beschleunigungssensor, auch Accelerometer genannt, ist ein Sensor, der seine Beschleunigung misst. Die Zeitreihe in Abbildung 2 wurde beispielsweise mit so einem Sensor gemessen. Es ist eine Messung der Beschleunigung in x-, y- und z-Richtung

möglich, wobei in Abbildung 2 die totale Beschleunigung, also die Summe der drei Richtungen, abgebildet ist. Es ist zu erkennen, dass sich die totale Beschleunigung je nach Aktivität unterscheidet.

- 4. Eine Zeitreihe T ist eine Folge von  $n \in N$  reellen Werten,  $T = (t_1, ..., t_n), t_i \in R$  [7]. Beispiele für Zeitreihen sind Aktienwerte oder Temperaturmessungen.
- 5. Eine Einschränkung der univarianten Zeitreihen stellen die stationären Zeitreihen dar. Dabei handelt es sich um Zeitreihen, dessen Werte unabhängig von der Zeit, an der sie aufgenommen wurden, sind. Sie zeigen dementsprechend ein Verhalten auf, das zu zeitunabhängigen Mittelwerten, Varianzen und Autokorrelationen führt. Es gibt also weder einen Trend noch Saisonalität [7]. In dieser Arbeit werden nur stationäre Zeitreihen betrachtet.
- 6. Eine Teilsequenz einer Zeitreihe T mit Startpunkt s und Endpunkt e besteht aus aufeinanderfolgenden Werten aus T von Position s bis e, d.h.  $T_{s,e} = (t_s,...,t_e)$ , wobei  $1 \le s \le e \le n$ . Die Länge von  $T_{s,e}$  ist  $|T_{s,e}| = e s + 1$  [7].
- 7. Die Änderungspunkte (kurz CP für "change point") sind genau die Stellen in der Zeitreihe bei denen ein Zustandwechsel des zugrundeliegenden Prozesses stattfindet. Bei CPD (kurz für "change point detection") werden die Positionen der Änderungspunkte ausgemacht.
- 8. Eine Segmentierung ist die geordnete Folge von Änderungspunkten [7].
- 9. Das Ziel von TSS ist, eine korrekte Segmentierung der Zeitreihe zu erzeugen.

Konkret in dem Bewegungsplanbeispiel in Abbildung 2 wird genau dann eine Änderung festgestellt, wenn die Aktivität wechselt. Die Zeitpunkte an dem die Wechsel stattfinden, sind die Änderungspunkte und jede Aktivität ist ein eigenes Segment.

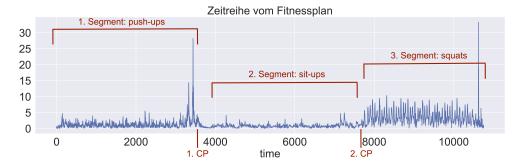


Abbildung 2: Zeitreihe mit drei Aktivitäten (push-up, sit-up, squat)

#### Verwandte Arbeiten

Für CPD und TSS wurden bereits eine Vielzahl an Algorithmen vorgestellt. Sehr viele dieser Algorithmen haben jedoch einen domänenspezifischen Ansatz, d.h. diese Lösungen können nicht auf alle Bereiche der HAR angewendet werden. Im Gegensatz dazu gibt es nur wenige domänenunabhängige der TSS und gegebenenfalls auch nicht für HAR [7]. ClaSP (Classification Score Profile) ist einer dieser domänenunabhängigen Algorithmen. Es handelt sich dabei um ein neues und genaues Verfahren für TSS und CPD.

Dafür berechnet ClaSP als erstes ein Klassifizierungsergebnisprofil (engl. Classification Score Profile) für eine gegebene Zeitreihe. Dieses Profil gibt für jeden Punkt der Zeitreihe einen Wert von 0 bis 1 an. Je höher der Wert im Profil ist, desto günstiger ist eine Segmentierung der Zeitreihe an dieser Stelle. Daraus folgt, dass im Ergebnisprofil

das globale Maximum gesucht wird. An diesem Änderungspunkt wird die Zeitreihe im nächsten Schritt geteilt, sodass es nun zwei Zeitreihen gibt. Für beide entstandenen Zeitreihen werden wieder ClaSPs berechnet. Innerhalb dieser Profile wird der größere der beiden Höhepunkte als zweiter Änderungspunkt ausgewählt. Die Zeitreihe mit diesem Punkt wird wieder in zwei Zeitreihen unterteilt, sodass nun drei Zeitreihen vorhanden sind. Auf diese Weise werden die Änderungspunkte rekursiv bestimmt bis die gewünschte Anzahl an Änderungspunkten erreicht ist [7].

Ein weiter domänenunspezifischer Algorithmus ist FLOSS [4]. Binary Segmentation (BinSeg) [13] sowie Bayesian Online Change Detection (BOCD) [1] sind domänenspezifische Ansätze, die Annahmen über die Werteverteilungen und Arten der Wechsel in Zeitreihen machen.

Wie bereits erwähnt ist das Ziel der Arbeit einen neuen Datensatz hervorzubringen. Es wurden schon einige Datensätze für HAR veröffentlicht, unter anderem [10], [8], [9], [1], [6] und [4]. Eine Übersicht der ersten 5 genannten Datensätze ist in Tabelle 2 zusehen, wobei ein vollständiger Überblick in [10] zu finden ist.

#### 4 Methodik

Der Datensatz soll insgesamt aus 20-30 Zeitreihen bestehen. Dabei sollten sich die Zeitreihen möglichst gut unterscheiden, damit ein diverser Datensatz entsteht und die Evaluation aussagekräftig ist. Die Differenzierung soll durch folgende Faktoren erreicht werden: unterschiedliche Bewegungsabläufe, Sensoren, Menschen, Länge der Zeitreihen und Anzahl der Segmente. Es werden insgesamt 4 bis 5 Personen aufgenommen, wobei nicht jede Zeitreihe mit allen Personen abgedeckt wird. Manche Zeitreihen werden folglich nur mit einer oder zwei Personen aufgenommen.

Für die Aufnahme der Daten wird die Handy-App "Physics Toolbox Sensor Suite" benutzt. Ich werde hauptsächlich mit dem Beschleunigungsmesser arbeiten, da dieser Sensor laut [10] einer der wichtigsten Sensortypen ist, um Aktivitäten wie sitzen, laufen, Treppen hoch-/runtersteigen sowie Fahrstuhl hoch-/runterfahren zu erkennen. Ein weiterer Sensor, mit dem wahrscheinlich Aufnahmen gemacht werden, ist das Gyroskop. Dieser Sensor misst Winkelgeschwindigkeiten, was ein wichtiger Faktor ist, um Sturzerkennungen auszumachen [10].

Die aufgenommenen Daten müssen im Anschluss noch aufbereitet werden. Die Aufbereitung erfolgt mit einem Ablauf, den ich mit der Programmiersprache Python schreiben werde. Dabei sollen die Daten zu festen Intervallen synchronisiert werden, wobei sich die Intervalllänge von Zeitreihe zu Zeitreihe unterscheiden kann. Eine Synchronisation ist wichtig, da die Sensoren bei der Aufnahme der Daten nicht immer in konstanten Intervallen aufzeichnen. Dieses Problem kann beispielsweise durch eine Interpolation gelöst werden.

#### 5 Evaluation

Nachdem die Zeitreihen aufbereitet wurden, werde ich ClaSP auf meinen Daten evaluieren. Als Evaluationsmetrik wird die gleiche Metrik verwendet wie in [3]. Es wird analysiert, wie gut der ClaSP Algorithmus die Zeitreihen segmentieren kann. Außerdem möchte ich die Performance von ClaSP mit zwei weiteren Algorithmen für TSS und CPD vergleichen. Hierbei soll nicht nur der Gesamtfehler über alle Zeitreihen sondern auch über andere Kriterien verglichen werden. Beispielsweise können die Zeitreihen in Gruppen eingeteilt werden mit folgenden Eigenschaften: Sensorarten, Sensorenplazierung, Aktivitätsanzahl und Aktivitätstypen. Auf diese Weise ist

Datenset	Anzahl	Aktivitäten	Sensoren
	der Sub- jekte		
MIT Pla- ceLab	1	Rezept zubereiten, Geschirr spülen, Küche reinigen, Wäsche waschen, Bett machen, Leichte Reinigung, Suche nach Ge-	3-Achsen- Beschleunigungsmesser, Herzfrequenzmonitor
		genständen, Geräte verwenden, Telefonieren, Mails beantworten	
UC Berkeley WARD	20 (13 männlich, 7 weib- lich)	Stehen, Sitzen, Liegen, Vorwärts gehen, Links gehen, Rechts ge- hen, Links abbiegen, Rechts ab- biegen, Treppe hochgehen, Trep- pe hinuntergehen, Joggen, Sprin- gen, Rollstuhl schieben	3-Achsen- Beschleunigungsmesser, 2-Achsen-Gyroskop
CMU MMAC	43	Zubereitung von Speisen, Fünf Rezepte kochen: Brownies, Piz- za, Sandwich, Salat, Rührei	Kamera, Mikrofon, 3-Achsen-Beschleunigungsmesser, 3-Achsen-Gyroskop, 3-Achsen-Magnetometer, Umgebungslicht, Wärmestromsensor, Galvanische Hautreaktion, Temperatur, Bewegungserfassung
OPPOR- TUNITY	12	Kaffee zubereiten, Kaffee trin- ken, Sandwich zubereiten, Sand- wich essen, Aufräumen	3-Achsen- Beschleunigungsmesser, 3-Achsen-Gyroskop, Achsen-Magnetometer, Mikrofon, Kamera, Druck- sensor, Leistungssensor
USC HAD	14 (7 männlich, 7 weib- lich)	Vorwärts gehen, Links gehen, Rechts gehen, Treppe hoch- gehen, Treppe hinuntergehen, Vorwärts rennen, Springen, auf einem Stuhl sitzen, Stehen, Schlafen, Aufzug nach oben fah- ren, Aufzug nach unten fahren	3-Achsen-Beschleunigungsmesser, 3-Achsen-Gyroskop

Tabelle 2: Vergleich zwischen existierenden HAR Datensets [10]

es möglich zu sehen, ob ein Algorithmus mit einer bestimmten Eigenschaft, wie z.B. mit wenig Aktivitäten oder einer Sensorart, besonders gut abschneidet. Die Ergebnisse sollen im Anschluss mithilfe von Boxplots, Diagrammen und Tabellen visualisiert werden. Folgende Vergleichsalgorithmen kommen in Frage: FLOSS, BinSeg-L2 und BOCD.

Am Ende der Evalution muss klar sein, ob ClaSP tatsälich einen geringeren Gesamtsegmentierungsfehler hat als die anderen Algorithmen.

### Literatur

- [1] Fernando De la Torre, Jessica Hodgins, Adam Bargteil, Xavier Martin, Justin Macey, Alex Collado, and Pep Beltran. Guide to the carnegie mellon university multimodal activity (cmu-mmac) database. 2009.
- [2] Biying Fu, Florian Kirchbuchner, and Arjan Kuijper. Unconstrained workout activity recognition on unmodified commercial off-the-shelf smartphones. In *Proceedings of the 13th ACM International Conference on PErvasive Technologies Related to Assistive Environments*, pages 1–10, 2020.
- [3] Shaghayegh Gharghabi, Yifei Ding, Chin-Chia Michael Yeh, Kaveh Kamgar, Liudmila Ulanova, and Eamonn Keogh. Matrix profile viii: domain agnostic online semantic segmentation at superhuman performance levels. In 2017 IEEE international conference on data mining (ICDM), pages 117–126. IEEE, 2017.
- [4] Nobuo Kawaguchi, Nobuhiro Ogawa, Yohei Iwasaki, Katsuhiko Kaji, Tsutomu Terada, Kazuya Murao, Sozo Inoue, Yoshihiro Kawahara, Yasuyuki Sumi, and Nobuhiko Nishio. Hasc challenge: Gathering large scale human activity corpus for the real-world activity understandings. 2011.
- [5] Oscar D. Lara and Miguel A. Labrador. A survey on human activity recognition using wearable sensors. *IEEE Communications Surveys & Tutorials*, 15(3):1192–1209, 2013.
- [6] Daniel Roggen, Alberto Calatroni, Mirco Rossi, Thomas Holleczek, Kilian Förster, Gerhard Tröster, Paul Lukowicz, David Bannach, Gerald Pirkl, Alois Ferscha, et al. Collecting complex activity datasets in highly rich networked sensor environments. In 2010 Seventh international conference on networked sensing systems (INSS), pages 233–240. IEEE, 2010.
- [7] Patrick Schäfer, Arik Ermshaus, and Ulf Leser. Clasp time series segmentation. In Gianluca Demartini, Guido Zuccon, J. Shane Culpepper, Zi Huang, and Hanghang Tong, editors, *Proceedings of the 30th ACM International Conference on Information & Knowledge Management*, pages 1578–1587, New York, NY, USA, 2021. ACM.
- [8] Emmanuel Munguia Tapia, Stephen S Intille, Louis Lopez, and Kent Larson. The design of a portable kit of wireless sensors for naturalistic data collection. In International conference on pervasive computing, pages 117–134. Springer, 2006.
- [9] Allen Y Yang, Roozbeh Jafari, S Shankar Sastry, and Ruzena Bajcsy. Distributed recognition of human actions using wearable motion sensor networks. *Journal of Ambient Intelligence and Smart Environments*, 1(2):103–115, 2009.
- [10] Mi Zhang and Alexander A Sawchuk. Usc-had: a daily activity dataset for ubiquitous activity recognition using wearable sensors. In *Proceedings of the 2012* ACM conference on ubiquitous computing, pages 1036–1043, 2012.