



# SEMINAR AKTIVITÄT SERKENNUNG

Organisation, Überblick, Themen

# Überblick heutige Veranstaltung

1. Organisatorisches
2. Aktivitätserkennung: eine Einführung
3. Kurzvorstellung der Themenvorschläge

# Überblick heutige Veranstaltung

1. Organisatorisches
2. Aktivitätserkennung: eine Einführung
3. Kurzvorstellung der Themenvorschläge

# Organisation

- Seminar mit 2 SWS (3 LP)
- Anrechenbar für Diplom, Bachelor
- Ansprechpartner:
  - Niels Landwehr, Raum 03.04.0.16, landwehr@cs.unipotsdam.de
  - Prof. Tobias Scheffer, Raum 03.04.0.17, scheffer@cs.unipotsdam.de
  
- Seminar: Raum 03.04.2.01
- Webseite:  
<http://www.cs.unipotsdam.de/ml/teaching/ss09/al.html>

# Organisation



- Veranstaltung wird als Blockseminar durchgeführt
  - Zwei Einführungstermine, 22.04. und 06.05. jeweils Mittwoch, 16-18 Uhr
  - Die Vorträge der Teilnehmer „im Block“ später im Semester
- Ablauf des Seminars
  - Verschiedene Themenstellungen aus dem Bereich der Aktivitätserkennung mit Literaturangaben
  - Jeder Teilnehmer/in wählt ein Thema, das er/sie selbstständig bearbeitet
  - Schriftliche Ausfertigung und Seminarvortrag (20min)

# Überblick heutige Veranstaltung

1. Organisatorisches
2. **Aktivitätserkennung: eine Einführung**
  1. Was ist Aktivitätserkennung?
  2. Typische Anwendungsbereiche
  3. Verwendete Techniken
3. Kurzvorstellung der Themenvorschläge

Aktivitätserkennung: Das automatische Erkennen der **Aktivität** oder der **Situation** eines oder mehrerer Benutzer basierend auf **Beobachtungen**

## □ **Aktivität**

### □ Erkennen der Aktivität eines Benutzers

- **Physische Aktivitäten:** Gehen, Laufen, Sitzen, Stehen, Treppen Steigen,...
- **Alltagsaktivitäten:** Kochen, Waschen, Essen, Fernsehen, Aufräumen,...
- **Komplexere Aktivitäten:** Interaktion mehrerer Benutzer, z.B. am Arbeitsplatz

# Aktivitätserkennung



Aktivitätserkennung: Das automatische Erkennen der **Aktivität** oder der **Situation** eines oder mehrerer Benutzer basierend auf **Beobachtungen**

## □ **Situation:**

### □ Erkennen einer bestimmten Situation von Interesse

- Verkehrsüberwachung: es hat sich ein Unfall ereignet/Stau gebildet
- Security Kameras: Es findet ein Einbruch statt
- ...

# Aktivitätserkennung



Aktivitätserkennung: Das automatische Erkennen der **Aktivität** oder der **Situation** eines oder mehrerer Benutzer basierend auf **Beobachtungen**

- **Beobachtungen:** durch Sensoren
  - Kontaktsensoren, Gewichtssensoren,...
  - Lokalisierung (GPS,...)
  - Kameras
  - Mikrophone
  - Beschleunigungssensoren
  - **RFID Sensoren**

# Sensoren: RFID

- RFID Sensoren: Beobachtung von Interaktion mit Objekten
  - Benutzer trägt (aktiven) Sensor, Objekt ist mit (passivem) „Tag“ versehen
  - RFID Sensor sendet Funkimpuls
  - Antenne im Tag fängt Signal auf, und sendet ID zurück

RFID Sensor  
(aktiv)



Tag (passiv)

- Detektion von Objekten, die sich nahe z.B. an der Hand des Benutzers befinden
- Kostengünstig (Tags wenige Cent)

# Überblick heutige Veranstaltung

1. Organisatorisches
2. **Aktivitätserkennung: eine Einführung**
  1. Was ist Aktivitätserkennung?
  2. **Typische Anwendungsbereiche**
  3. Verwendete Techniken
3. Kurzvorstellung der Themenvorschläge

# Anwendungsgebiete Aktivitätserkennung



- Kurzer Überblick über zwei wichtige Anwendungsgebiete
  1. „Assisted Living“
  2. Erkennen von Aktivitäten/Situationen in Kamerabildern

# Anwendungsgebiete: Assisted Living

- „Assisted Living“:
  - Unterstützung älterer Menschen, die allein zu Hause wohnen
  - Überwachung/Unterstützung beim Alltagsleben
- Korrekte Ausführung von Alltagsaktivitäten?
  - Wichtiger Indikator für medizinische Verfassung (Alzheimer, Parkinson, ...)
  - Vermeidung von Problemen/Gefahren (Herd aus?)
- Momentan manuelle Erfassung
  - Fragebögen, die mit Betreuungspersonal ausgefüllt werden

# Anwendungsgebiete: Assisted Living

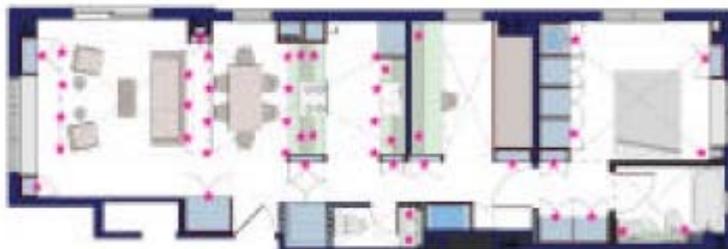
- „Smart Home“ Idee
  - ▣ Automatisches Erkennen der Aktivitäten der Bewohner
  - ▣ Kann unterstützend eingreifen oder Hilfe holen
- Umfangreiche Forschung: z.B. „PlaceLab“ Projekt
  - ▣ Speziell zu diesem Zweck gebautes Forschungs-Apartment
  - ▣ Ausgestattet mit hunderten von Sensoren
    - Kameras, Mikrophone
    - Licht, Elektrizität, Wasser, ...
    - RFID Tags an vielen Objekten, mobile RFID Sensoren
    - ...

# PlaceLab Apartment



- Experimente mit „Bewohnern“ die mehrere Wochen dort leben und (möglichst realitätsnahe) Alltagsaktivitäten ausführen

# PlaceLab Apartment



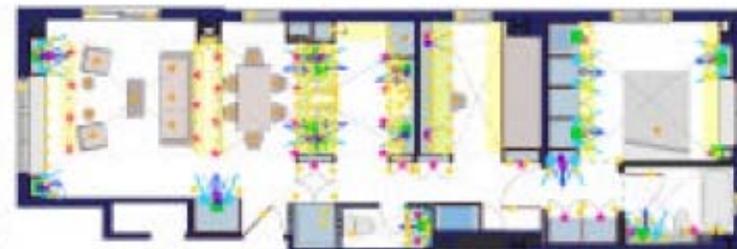
IR Transmitters for Location and Identity



Switch sensors in cabinetry doors, appliances, etc.



Wireless Sensors for Use of Movable Furniture

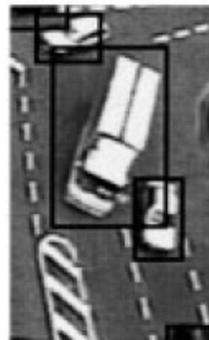


Composite Plan Showing All Sensors

- Erfassung und zentrale Speicherung aller Sensordaten
- Aktivitäten der Benutzer werden aufgezeichnet
- Versuch, Aktivitäten aus Sensordaten vorherzusagen

# Anwendungsgebiete: Interpretation von Kamerabildern

- Automatische Auswertung von Kamerabildern
  - Immer mehr Kameras, kaum möglich alles Material zu sichten/auszuwerten
  - Automatisches Erkennen „interessanter“ Situationen
    - Verkehr: Stau, Unfälle
    - Security: Einbrüche, Banküberfälle, Terrorabwehr,...



# Anwendungsgebiete: Interpretation von Kamerabildern



- Aktivitätserkennung in der Kritik
  - Privatsphäre
  - Missbrauchsgefahr
  - ...abwägen zwischen Nutzen und Gefahren

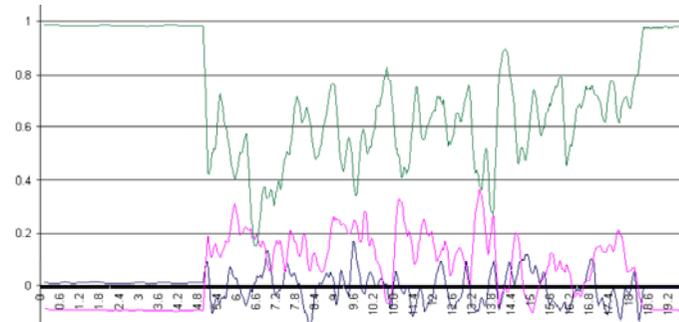
# Überblick heutige Veranstaltung

1. Organisatorisches
2. **Aktivitätserkennung: eine Einführung**
  1. Was ist Aktivitätserkennung?
  2. Typische Anwendungsbereiche
  3. **Verwendete Techniken**
3. Kurzvorstellung der Themenvorschläge
4. Themenwahl, Terminabstimmung, etc.

# Techniken zur Aktivitätserkennung

## □ Aufgabe: Interpretation von Sensordaten

Beschleunigungssensoren: 3-dimensionaler Beschleunigungsvektor, gemessen z.B. am Handgelenk



RFID-Tags: z.B. Sequenz von Objekten, die ein Benutzer berührt hat

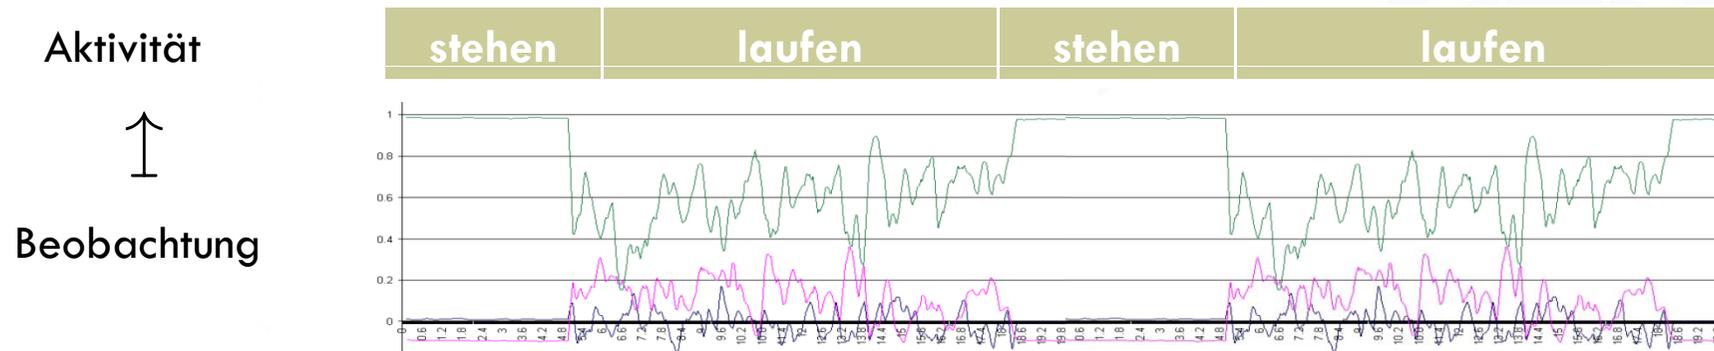
	toast	toast	toaster	toaster	toaster	toaster	toast	toast	knife	knife	knife	butter	butter	toast	toast	knife	knife	jam	jam
01	02	03	04	05	06	07	08	09	10	11	12	13	14	15	16	17	18	19	

Kamera: Sequenz von Bildern, z.B. Verkehrsüberwachung



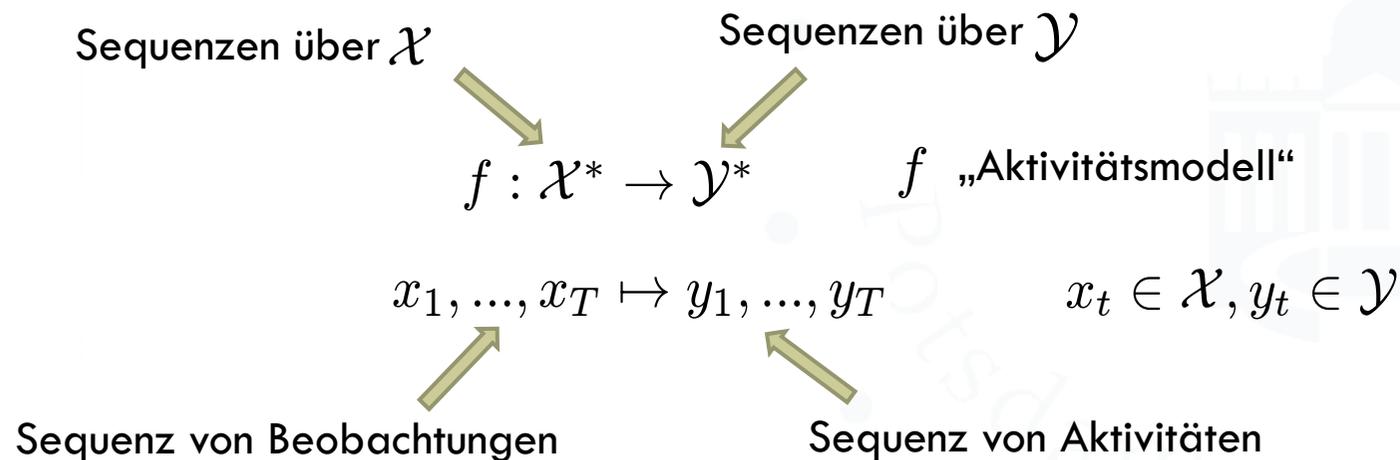
# Problemstellung

- Dynamisches Problem
  - ▣ Aktivitäten / Sensorbeobachtungen verändern sich
  - ▣ In der Regel hilfreich bei der Problemlösung (wir sollten die Zeitschritte nicht unabhängig betrachten)
- Aktivitätserkennung: annotieren einer Sequenz von Beobachtungen



# Formalere Problemstellung

- Gegeben
  - ▣ Raum von Beobachtungen  $\mathcal{X}$
  - ▣ Raum von Aktivitäten/Situationen/...  $\mathcal{Y}$
- Gesucht: Aktivitätsmodell



# Problemstellung: Beispiel

## □ 3D-Beschleunigungssensor

$$\mathcal{X} = \mathbb{R}^3$$

Sensor: Pro Zeitpunkt ein 3D Vektor

$$\mathcal{Y} = \{\text{stehen, gehen, laufen}\}$$

Menge von Aktivitäten

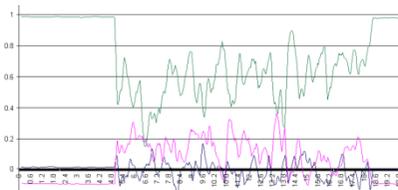
laufen, laufen, laufen, gehen, stehen  $\in \mathcal{Y}^*$

$\uparrow f$

$$\begin{pmatrix} 0.15 \\ 0.75 \\ 0.2 \end{pmatrix}, \begin{pmatrix} 0.18 \\ 0.65 \\ 0.2 \end{pmatrix}, \begin{pmatrix} 0.2 \\ 0.6 \\ 0.25 \end{pmatrix}, \begin{pmatrix} 0.12 \\ 0.35 \\ 0.15 \end{pmatrix}, \begin{pmatrix} 0.01 \\ 0.05 \\ 0.0 \end{pmatrix} \in \mathcal{X}^*$$

# Konstruktion des Aktivitätsmodells

- Woher kommt das Aktivitätsmodell  $f$  ?
- Manuelle Implementierung? Problematisch:
  - ▣ Oft unklar, wie Interpretation der Sensordaten algorithmisch lösbar



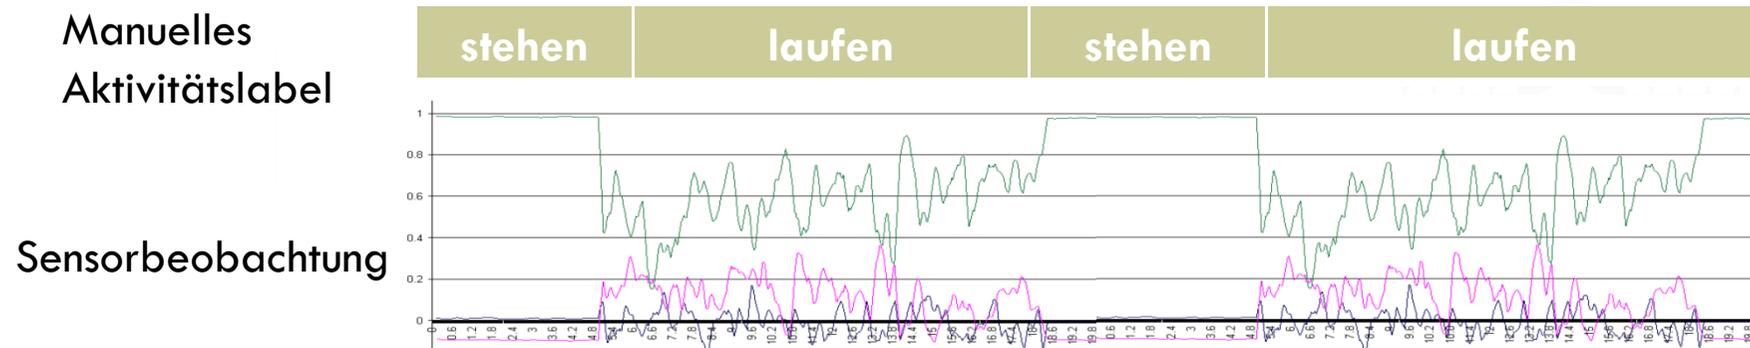
	toast	toast	toaster	toaster	toaster	toaster	toast	toast	knife	knife	knife	butter	butter
01	02	03	04	05	06	07	08	09	10	11	12	13	



- ▣ Großer Arbeitsaufwand – neuer Algorithmus für jede Aktivität (und möglicherweise jeden Nutzer)

# Lernen von Aktivitätsmodellen

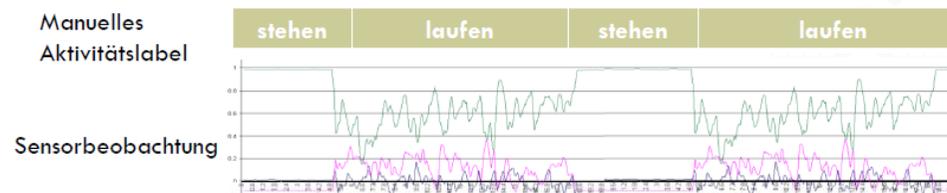
- Einfacher als einen Algorithmus zu entwickeln: Daten sammeln
  - ▣ Benutzer in Umgebung beobachten, Aktivität notieren
  - ▣ Parallel dazu Sensordaten aufzeichnen



- Automatisches *Lernen* von Aktivitätsmodellen aus diesen Daten

# Lernen von Aktivitätsmodellen

- Ansatz des maschinellen Lernens
  - ▣ Gegeben Beobachtungen (Sensordaten + Aktivitätslabel)



- ▣ Finde ein Modell, das die Beobachtungen erklärt

- Deterministisches Modell:

$$f : \mathcal{X}^* \rightarrow \mathcal{Y}^*$$

$f(\text{Sensordaten}) = \text{Aktivitätslabel}$  auf den Trainingsdaten [naiv]

- Probabilistisches Modell: Wahrscheinlichkeitsverteilung

$$p(\mathcal{X}^*, \mathcal{Y}^*) \text{ oder } p(\mathcal{Y}^* | \mathcal{X}^*)$$

so dass Wahrscheinlichkeit der Beobachtungen hoch

# Lernen von Aktivitätsmodellen

- Maschinelles Lernen: Definiere Lernproblem
  - Modellraum (welche Modelle in Erwägung ziehen?)
  - Zielfunktion (wie Modelle bewerten?)
  - Suchproblem lösen (wie „bestes“ Modell finden?)
  
- Maschinelles Lernen Standardansatz in der Aktivitätserkennung
  - Effektivste bekannte Methode zur Aktivitätserkennung
  - Es existieren viele Verfahren: Hidden Markov Modelle (HMMs), Nearest Neighbor, Entscheidungsbäume,...
  - Mehr in Seminarvorträgen!

# Überblick heutige Veranstaltung

1. Organisatorisches
2. Aktivitätserkennung: eine Einführung
3. **Kurzvorstellung der Themenvorschläge**

# Themenvorschläge



- Anwendung
1. „Aktivitätserkennung mit RFID Tags“
  2. „Aktivitätserkennung mit RFID Tags und Web Mining“
  3. „Aktivitätserkennung mit Beschleunigungssensoren“
  4. „Erkennung des Fahrerverhaltens in einem SmartCar“
  5. „Erkennen und Lernen von Bewegungsmustern“
  6. „Rekonstruktion von 3D Bewegungen aus 2D Videodaten“
  7. „Identifikation von Individuen anhand von Gang-Merkmalen“
- ML
8. „Diskriminative vs. generative Modelle für die Aktivitätserkennung“
  9. „Halbüberwachtes und aktives Lernen für die Aktivitätserkennung“
  10. „Erkennung von unterbrochenen Aktivitäten mit Hidden Markov Modellen“

Vorwissen im Bereich maschinelles Lernen für einige Themen empfehlenswert!

# Themenvorschläge



Anwendung

1. „Aktivitätserkennung mit RFID Tags“
2. „Aktivitätserkennung mit RFID Tags und Web Mining“
3. „Aktivitätserkennung mit Beschleunigungssensoren“
4. „Erkennung des Fahrerverhaltens in einem SmartCar“
5. „Erkennen und Lernen von Bewegungsmustern“
6. „Rekonstruktion von 3D Bewegungen aus 2D Videodaten“
7. „Identifikation von Individuen anhand von Gang-Merkmalen“

ML

8. „Diskriminative vs. generative Modelle für die Aktivitätserkennung“
9. „Halbüberwachtes und aktives Lernen für die Aktivitätserkennung“
10. „Erkennung von unterbrochenen Aktivitäten mit Hidden Markov Modellen“

Vorwissen im Bereich maschinelles Lernen für einige Themen empfehlenswert!

# 1. Aktivitätserkennung mit RFID Tags

- Problemstellung: Erkennung von Alltagsaktivitäten basierend auf RFID
  - ▣ Benutzer trägt RFID Sensor
  - ▣ Gegenstände des täglichen Lebens sind mit RFID Tags versehen

Sensor



Objekt mit Tag

- Sensorbeobachtung: Sequenz von Objekten, die nahe an der Hand des Benutzers (ca. 10-20 cm) sind

01	toast	18	jam	25	cup
02	toast	19	jam	26	spoon
03	toaster	20	water	27	spoon
04	toaster	21	water	28	sugar
05	toaster	22	water	29	sugar
06	toaster	23	stove	30	cup
07	toast	24	stove		
08	toast				
09	knife				
10	knife				
11	knife				
12	butter				
13	butter				
14	toast				
15	toast				
16	knife				
17	knife				

# 1. Aktivitätserkennung mit RFID Tags

- Rekonstruiere Aktivität aus beobachteten Objekten

Aktivität	ToastBread								FlavorToast							BoilWater				FlavorTea										
Sensorbeob.	01	02	03	04	05	06	07	08	09	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
	toast	toast	toaster	toaster	toaster	toaster	toast	toast	knife	knife	knife	butter	butter	toast	toast	knife	knife	jam	jam	water	water	water	stove	stove	cup	spoon	spoon	sugar	sugar	cup

- Lösung mit maschinellem Lernen: Lerne Aktivitätsmodell aus Trainingsbeispielen
  - Modellklasse: Hidden Markov Modelle
- Ergebnis: Genaue Aktivitätsvorhersage möglich für verschiedene Alltagsaktivitäten

Literatur:

D. Patterson, D. Fox, H.Kautz, M. Philipose. "Fine-Grained Activity Recognition by Aggregating Abstract Object Usage". Proceedings of the 9th IEEE International Symposium on Wearable Computers, 2005

# Themenvorschläge



Anwendung

1. „Aktivitätserkennung mit RFID Tags“
2. „Aktivitätserkennung mit RFID Tags und Web Mining“
3. „Aktivitätserkennung mit Beschleunigungssensoren“
4. „Erkennung des Fahrerverhaltens in einem SmartCar“
5. „Erkennen und Lernen von Bewegungsmustern“
6. „Rekonstruktion von 3D Bewegungen aus 2D Videodaten“
7. „Identifikation von Individuen anhand von Gang-Merkmalen“

ML

8. „Diskriminative vs. generative Modelle für die Aktivitätserkennung“
9. „Halbüberwachtes und aktives Lernen für die Aktivitätserkennung“
10. „Erkennung von unterbrochenen Aktivitäten mit Hidden Markov Modellen“

Vorwissen im Bereich maschinelles Lernen für einige Themen empfehlenswert!

## 2. Aktivitätserkennung mit RFID Tags und Web Mining



- Ähnliche Problemstellung: Aktivitätserkennung mit RFID Tags
- Ziel: Reduktion des manuellen Aufwands beim Lernen der Aktivitätsmodelle
  - Hauptaufwand ist das „Labeln“ der Sensordaten (annotieren mit aktueller Aktivität)

Aktivitätslabel	ToastBread								FlavorToast								BoilWater				FlavorTea									
Sensorbeobachtung	toast	toast	toaster	toaster	toaster	toaster	toast	toast	knife	knife	knife	butter	butter	toast	toast	knife	knife	jam	jam	water	water	water	stove	stove	cup	spoon	spoon	sugar	sugar	cup
	01	02	03	04	05	06	07	08	09	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30

- Ziel: Kein manuelles „Labeln“

## 2. Aktivitätserkennung mit RFID Tags und Web Mining

- Stattdessen: extrahiere Assoziationen zwischen Objekten und Aktivitäten aus dem WWW („HOW-TOs“):

Implizit steckt Wissen über Objektbenutzung im WWW

Making Tea:

1. Fill a **teapot** from the **faucet**. Place kettle on the **stove** and boil.
2. Pour hot **water** into a **cup**, filling  $\frac{3}{4}$  of the cup. Immerse **teabag** in cup for two minutes and dispose of teabag.
3. Add **milk** and **sugar** to taste.

- Schätze Wahrscheinlichkeit, dass bestimmte Objekte in Aktivitäten vorkommen (anhand Texte im WWW)
- Initiale Modelle, „Unüberwachtes“ Lernen von Sensordaten
- Ergebnis: Relativ gute Vorhersagen *ohne manuelles Labeln* möglich

Literatur:

D. Wyatt, M. Philipose, T. Choudhury. "Unsupervised Activity Recognition Using Automatically Mined Common Sense". Proceedings of the 20th National Conference on Artificial Intelligence, 2005.

# Themenvorschläge



Anwendung

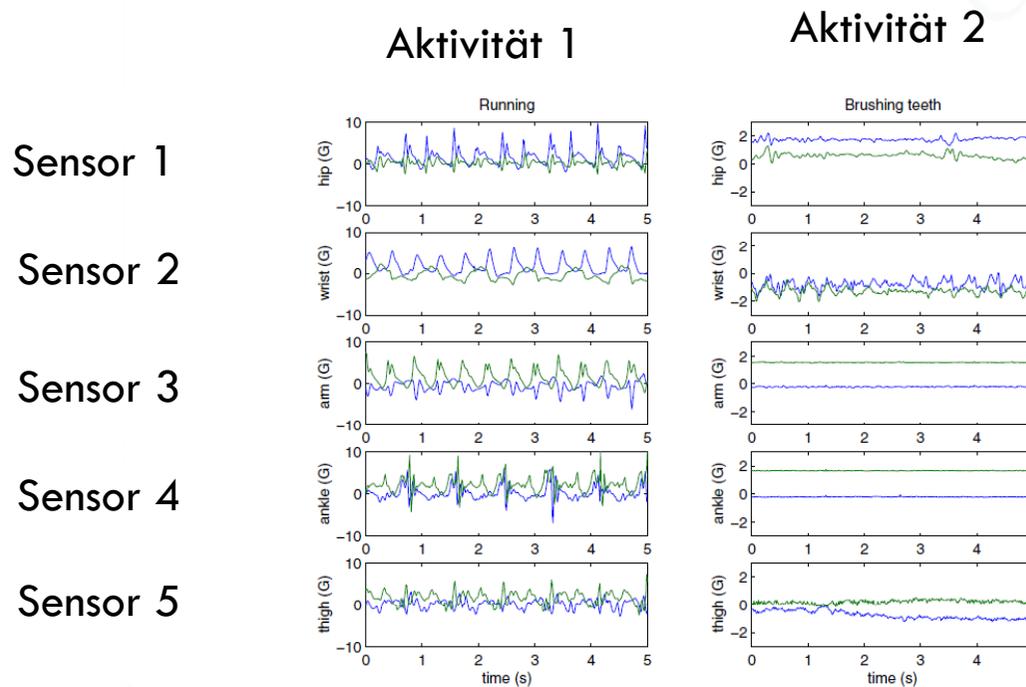
1. „Aktivitätserkennung mit RFID Tags“
2. „Aktivitätserkennung mit RFID Tags und Web Mining“
3. „Aktivitätserkennung mit Beschleunigungssensoren“
4. „Erkennung des Fahrerverhaltens in einem SmartCar“
5. „Erkennen und Lernen von Bewegungsmustern“
6. „Rekonstruktion von 3D Bewegungen aus 2D Videodaten“
7. „Identifikation von Individuen anhand von Gang-Merkmalen“
8. „Diskriminative vs. generative Modelle für die Aktivitätserkennung“
9. „Halbüberwachtes und aktives Lernen für die Aktivitätserkennung“
10. „Erkennung von unterbrochenen Aktivitäten mit Hidden Markov Modellen“

ML

Vorwissen im Bereich maschinelles Lernen für einige Themen empfehlenswert!

# 3. Aktivitätserkennung mit Beschleunigungssensoren

- Problemstellung: Erkennung einfacher Aktivitäten mit Hilfe von Beschleunigungssensoren
  - ▣ Benutzer trägt mehrere Sensoren



## 3. Aktivitätserkennung mit Beschleunigungssensoren

- Überwachtes Lernen (=mit Labeln) von Aktivitätsmodellen (für 20 Aktivitäten)
- Verschiedene Modellklassen
  - Nearest Neighbor, Entscheidungsbäume, Naive Bayes,...
- Ergebnisse
  - Erkennungsraten zwischen 97% („working with computer“) und 43% („riding elevator“)

Literatur:

L. Bao, S. Intille. "Activity Recognition from User-Annotated Acceleration Data". Proceedings of the 2nd International Conference on Pervasive Computing, 2004

# Themenvorschläge



Anwendung

1. „Aktivitätserkennung mit RFID Tags“
2. „Aktivitätserkennung mit RFID Tags und Web Mining“
3. „Aktivitätserkennung mit Beschleunigungssensoren“
4. „Erkennung des Fahrerverhaltens in einem SmartCar“
5. „Erkennen und Lernen von Bewegungsmustern“
6. „Rekonstruktion von 3D Bewegungen aus 2D Videodaten“
7. „Identifikation von Individuen anhand von Gang-Merkmalen“

ML

8. „Diskriminative vs. generative Modelle für die Aktivitätserkennung“
9. „Halbüberwachtes und aktives Lernen für die Aktivitätserkennung“
10. „Erkennung von unterbrochenen Aktivitäten mit Hidden Markov Modellen“

Vorwissen im Bereich maschinelles Lernen für einige Themen empfehlenswert!

# 4. Erkennen des Fahrerverhaltens in einem SmartCar



- Problemstellung: „taktische“ Fahrmanöver im Auto erkennen
  - Spurwechsel, Überholen, Abbiegen, Anhalten,...
- „SmartCar“ mit umfangreicher Sensorik
  - Gas, Steuerrad, Bremsen, Gang,...
  - Umgebender Verkehr (über Kameras)
  - Blickrichtung des Fahrers
- Charakteristische Sensorbeobachtungen für Manöver

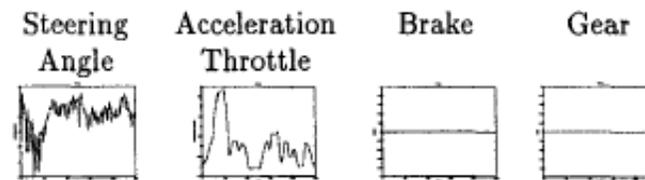


Figure 3: Typical car signals for a passing maneuver

# 4. Erkennen des Fahrerverhaltens in einem SmartCar



- Maschinelles Lernen mit Hidden Markov Modellen
- Ergebnis:
  - Erkennung der Manöver mit unterschiedlicher Genauigkeit

Accuracy (%)			
	Car	Car & Lane	Car & Gaze
pass	100.0	100.0	100.0
turn right	71.4	85.7	85.7
turn left	0.0	33.3	66.7
change lane right	0.0	12.5	6.3
change lane left	29.4	17.6	23.5
start	100.0	66.7	83.3
stop	100.0	100.0	100.0

- Typischerweise möglich Manöver vor der eigentlichen Ausführung zu erkennen

Literatur:

N. Oliver, A. Pentland. "Graphical Models for Driver Behavior Recognition in a SmartCar". Proceedings of the IEEE Intelligent Vehicle Symposium, 2000

# Themenvorschläge



Anwendung

1. „Aktivitätserkennung mit RFID Tags“
2. „Aktivitätserkennung mit RFID Tags und Web Mining“
3. „Aktivitätserkennung mit Beschleunigungssensoren“
4. „Erkennung des Fahrerverhaltens in einem SmartCar“
5. „Erkennen und Lernen von Bewegungsmustern“
6. „Rekonstruktion von 3D Bewegungen aus 2D Videodaten“
7. „Identifikation von Individuen anhand von Gang-Merkmalen“

ML

8. „ Diskriminative vs. generative Modelle für die Aktivitätserkennung“
9. „ Halbüberwachtes und aktives Lernen für die Aktivitätserkennung“
10. „Erkennung von unterbrochenen Aktivitäten mit Hidden Markov Modellen“

Vorwissen im Bereich maschinelles Lernen für einige Themen empfehlenswert!

## 5. Erkennen und Lernen von Bewegungsmustern

- Problemstellung: Erkennen und Lernen typischer Bewegungsmustern von Benutzern
  - Gleichzeitige Erkennung von *typischen Routen* und *Transportmitteln* (zu Fuss/Auto/Bus/...) im städtischen Raum
- Sensordaten: GPS

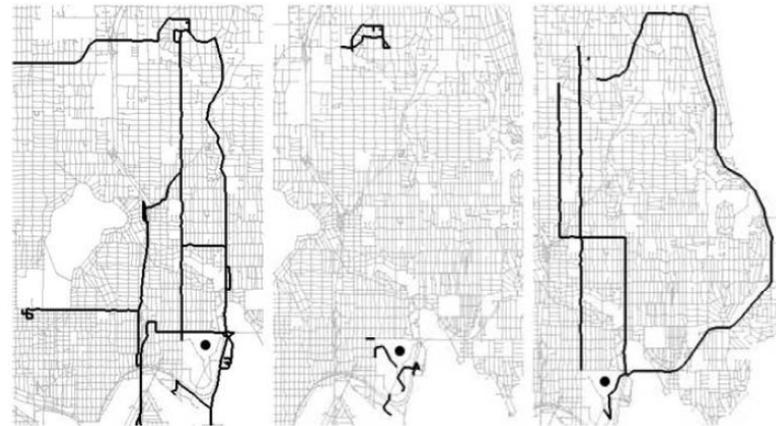


Fig. 3. Car (left), Foot (middle), and Bus (right) training data used for experiments. The black dot is a common map reference point on the University of Washington campus.

# 5. Erkennen und Lernen von Bewegungsmustern



- **Verwendete Methoden**
  - Probabilistische Graphische Modelle
  - Bayessche Methoden
  - Particle Filters
  - Expectation-Maximization
- ...Thema technisch etwas anspruchsvoller, Vorwissen im Bereich des maschinellen Lernens empfehlenswert!

## Literatur

D. Patterson, L. Liao, D. Fox, H. Kautz. "Inferring High-Level Behavior from Low-Level Sensors". Proceedings of the 5th International Conference on Ubiquitous Computing

# Themenvorschläge



Anwendung

1. „Aktivitätserkennung mit RFID Tags“
2. „Aktivitätserkennung mit RFID Tags und Web Mining“
3. „Aktivitätserkennung mit Beschleunigungssensoren“
4. „Erkennung des Fahrerverhaltens in einem SmartCar“
5. „Erkennen und Lernen von Bewegungsmustern“
6. „Rekonstruktion von 3D Bewegungen aus 2D Videodaten“
7. „Identifikation von Individuen anhand von Gang-Merkmalen“

ML

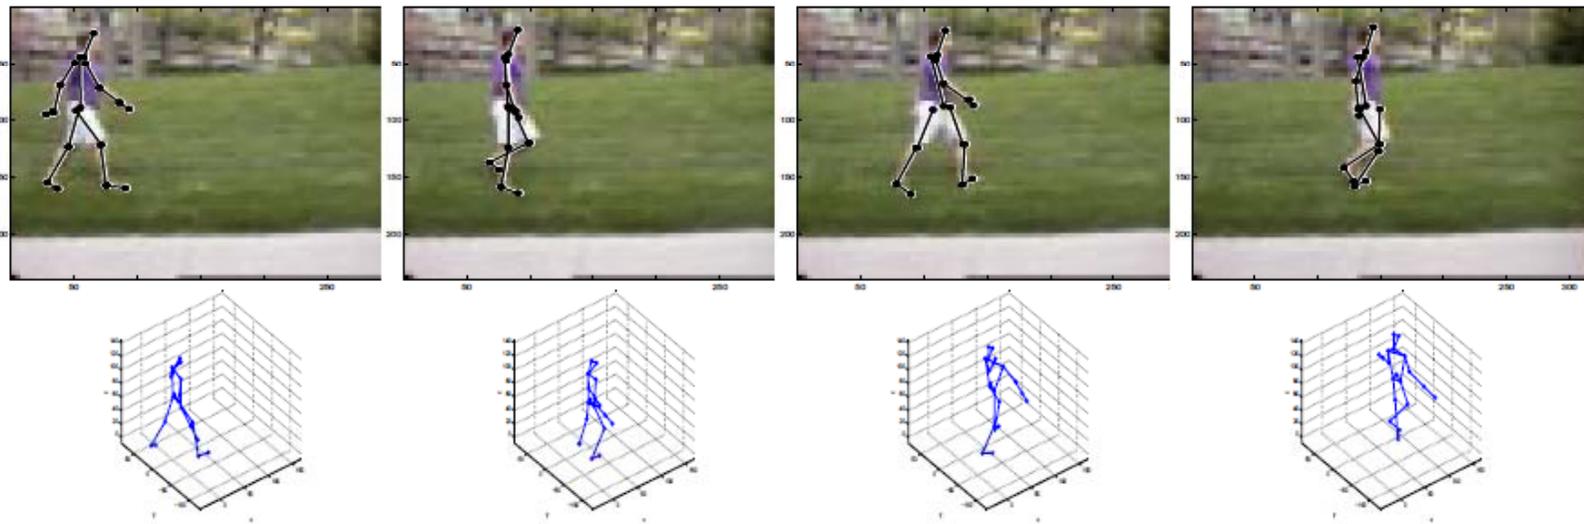
8. „Diskriminative vs. generative Modelle für die Aktivitätserkennung“
9. „Halbüberwachtes und aktives Lernen für die Aktivitätserkennung“
10. „Erkennung von unterbrochenen Aktivitäten mit Hidden Markov Modellen“

Vorwissen im Bereich maschinelles Lernen für einige Themen empfehlenswert!

# 6. Rekonstruktion von 3D Bewegungen aus 2D Videodaten



- Problemstellung: Erkennen von 3D Bewegungsfolgen in 2D Videodaten
  - Nicht-trivial: „unterbestimmtes“ Problem (Mehrdeutigkeit, verschiedene 3D Bewegungen können dieselben 2D Bilder ergeben)



# 6. Rekonstruktion von 3D Bewegungen aus 2D Videodaten



- Idee: Lerne ein Modell für typische Bewegungen in 3D
  - Trainingsbeispiele: „echte“ 3D Bewegungsdaten aus Motion-Capture System
- Benutze dieses Modell, um Mehrdeutigkeiten aufzulösen
  - Berechne die wahrscheinlichste 3D Bewegungsfolge, gegeben 3D-Modell und 2D-Observationen
- Verwendete Methoden
  - Gaussche Mixture-Modelle, Expectation-Maximization
  - Etwas Vorwissen im Bereich maschinelles Lernen wäre hilfreich!
- Ergebnis: kurze Bewegungsfolgen können mit hoher Genauigkeit rekonstruiert werden

Literatur:

N. Howe, M. Leventon, W. Freeman. "Bayesian Reconstruction of 3D Human Motion from Single-Camera Video". Advances in Neural Information Processing Systems 12, 2000

# Themenvorschläge



Anwendung

1. „Aktivitätserkennung mit RFID Tags“
2. „Aktivitätserkennung mit RFID Tags und Web Mining“
3. „Aktivitätserkennung mit Beschleunigungssensoren“
4. „Erkennung des Fahrerverhaltens in einem SmartCar“
5. „Erkennen und Lernen von Bewegungsmustern“
6. „Rekonstruktion von 3D Bewegungen aus 2D Videodaten“
7. **„Identifikation von Individuen anhand von Gang-Merkmalen“**
8. „Diskriminative vs. generative Modelle für die Aktivitätserkennung“
9. „Halbüberwachtes und aktives Lernen für die Aktivitätserkennung“
10. „Erkennung von unterbrochenen Aktivitäten mit Hidden Markov Modellen“

ML

Vorwissen im Bereich maschinelles Lernen für einige Themen empfehlenswert!

# 7. Identifikation von Individuen anhand von Gang-Merkmalen

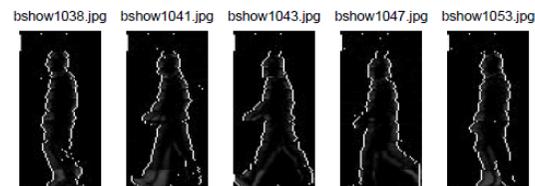
- Umgekehrte Problemstellung: erkenne einen *Benutzer* an der Art wie er eine *Aktivität* ausführt
  - ▣ Betrachtete Aktivität „Gehen“
  - ▣ Anwendungen in der Biometrie
- Sensordaten: Kamerabilder

Person 1



(a)

Person 2



(b)

# 7. Identifikation von Individuen anhand von Gang-Merkmalen



- Verfahren: Lerne ein Modell für jede Person
  - Kontinuierliche Hidden Markov Modelle
- Erkennung
  - Weise Beobachtungssequenz dem Modell (=der Person) zu, für das Wahrscheinlichkeit der Beobachtung am höchsten ist
- Ergebnisse:
  - 25 Personen: Erkennung nicht genau genug um einzelne Person zu identifizieren
  - Gut genug, um Personenkreis einzuschränken (Kombinieren mit anderen Verfahren...)

## Literatur

A. Kale, A. Rajagopalan, N. Cuntoor, V. Krueger. "Gait-based Recognition of Humans using Continuous HMMs".  
Proceedings of the 5th IEEE International Conference on Automatic Face and Gesture Recognition, 2002.

# Themenvorschläge



Anwendung

1. „Aktivitätserkennung mit RFID Tags“
2. „Aktivitätserkennung mit RFID Tags und Web Mining“
3. „Aktivitätserkennung mit Beschleunigungssensoren“
4. „Erkennung des Fahrerverhaltens in einem SmartCar“
5. „Erkennen und Lernen von Bewegungsmustern“
6. „Rekonstruktion von 3D Bewegungen aus 2D Videodaten“
7. „Identifikation von Individuen anhand von Gang-Merkmalen“
8. „Diskriminative vs. generative Modelle für die Aktivitätserkennung“
9. „Halbüberwachtes und aktives Lernen für die Aktivitätserkennung“
10. „Erkennung von unterbrochenen Aktivitäten mit Hidden Markov Modellen“

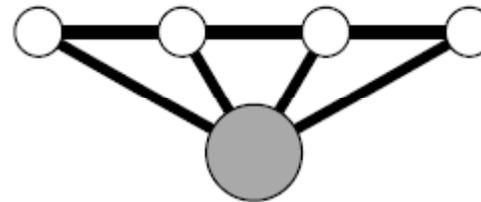
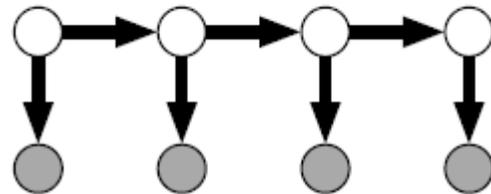
ML

Vorwissen im Bereich maschinelles Lernen für einige Themen empfehlenswert!

## 8. Diskriminative versus Generative Modelle für die Aktivitätserkennung

- Themenstellung: Vergleich zweier verschiedener Modellklassen in der Aktivitätserkennung
  - ▣ Hidden Markov Modelle (generativ)
  - ▣ Conditional Random Fields (diskriminativ)

HMM



CRF

## 8. Diskriminative versus Generative Modelle für die Aktivitätserkennung

- Vergleich in einer simulierten Multi-Roboter Umgebung
  - Roboter haben verschiedene Rollen/Ziele, die ihr Verhalten beeinflussen
  - Problemstellung: Erkennen der Rolle eines Roboters
  - Sensordaten: Positionen der Roboter
- Ergebnisse: Diskriminative Modelle (CRFs) oft besser als generative Modelle (HMMs)

Literatur:

D. Vail, M. Veloso, J. Lafferty. "Conditional Random Fields for Activity Recognition". Proceedings of the 2007 Conference on Autonomous Agents and Multiagent Systems, 2007

# Themenvorschläge



Anwendung

1. „Aktivitätserkennung mit RFID Tags“
2. „Aktivitätserkennung mit RFID Tags und Web Mining“
3. „Aktivitätserkennung mit Beschleunigungssensoren“
4. „Erkennung des Fahrerverhaltens in einem SmartCar“
5. „Erkennen und Lernen von Bewegungsmustern“
6. „Rekonstruktion von 3D Bewegungen aus 2D Videodaten“
7. „Identifikation von Individuen anhand von Gang-Merkmalen“

ML

8. „Diskriminative vs. generative Modelle für die Aktivitätserkennung“
9. „Halbüberwachtes und aktives Lernen für die Aktivitätserkennung“
10. „Erkennung von unterbrochenen Aktivitäten mit Hidden Markov Modellen“

Vorwissen im Bereich maschinelles Lernen für einige Themen empfehlenswert!

# 9. Halbüberwachtes und Aktives Lernen für die Aktivitätserkennung



- Themenstellung behandelt *halbüberwachtes* und *aktives* Lernen in der Aktivitätserkennung
- Ziel: Reduktion des manuellen Aufwands beim Lernen der Aktivitätsmodelle (vgl. Thema 3)
  - Hauptaufwand ist das „Labeln“ der Sensordaten (annotieren mit aktueller Aktivität)
  - Halbüberwachtes Lernen: benutzt eine Mischung aus „gelabelten“ und „ungelabelten“ Daten
  - Aktives Lernen: während des Lernvorgangs werden nur die informativsten Label vom Lernverfahren „angefordert“

# 9. Halbüberwachtes und Aktives Lernen für die Aktivitätserkennung



- Problemstellung: Erkennung von Alltagsaktivitäten
  - Daten aus dem „PlaceLab“ Apartment
  - Sensoren: Beschleunigungssensoren (am Benutzer), Infrarotsensoren (im Gebäude)
- Methoden/Modelle
  - Naive Bayes, Entscheidungsbäume, ...
  - Halbüberwachtes Lernen, aktives Lernen
- Ergebnisse:
  - Halbüberwachtes und aktives Lernen erreichen gleiche Erkennungsraten mit deutlich weniger „Labeling“

Literatur:

M. Stikic, K. Laerhoven, B. Schiele. "Exploring Semi-Supervised and Active Learning for Activity Recognition". Proceedings of the 12th IEEE International Symposium on Wearable Computers, 2008.

# Themenvorschläge



Anwendung

1. „Aktivitätserkennung mit RFID Tags“
2. „Aktivitätserkennung mit RFID Tags und Web Mining“
3. „Aktivitätserkennung mit Beschleunigungssensoren“
4. „Erkennung des Fahrerverhaltens in einem SmartCar“
5. „Erkennen und Lernen von Bewegungsmustern“
6. „Rekonstruktion von 3D Bewegungen aus 2D Videodaten“
7. „Identifikation von Individuen anhand von Gang-Merkmalen“

ML

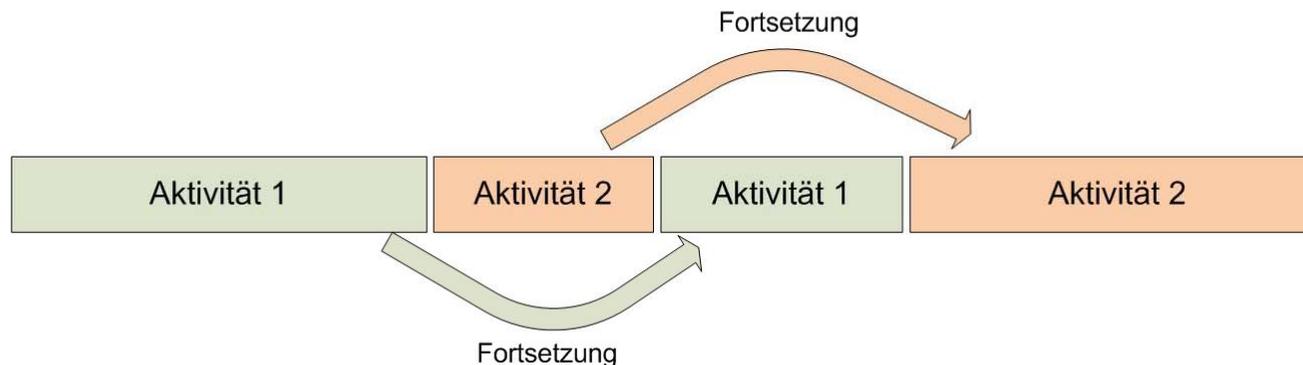
8. „Diskriminative vs. generative Modelle für die Aktivitätserkennung“
9. „Halbüberwachtes und aktives Lernen für die Aktivitätserkennung“
10. „Erkennung von unterbrochenen Aktivitäten mit Hidden Markov Modellen“

Vorwissen im Bereich maschinelles Lernen für einige Themen empfehlenswert!

# 10. Erkennung von unterbrochenen Aktivitäten mit Hidden Markov Modellen



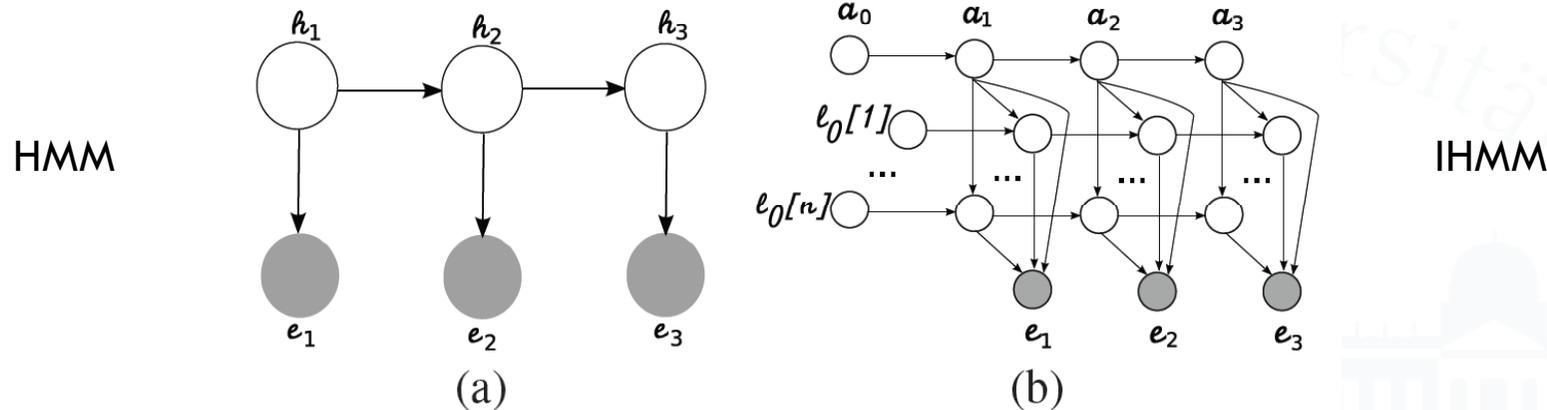
- Problemstellung: Erkennen von Aktivitäten die *unterbrochen* und/oder *verschränkt* sind
  - ▣ Benutzer unterbricht eine Aktivität um eine andere auszuführen



- Spezielle Klasse von Modellen für dieses Szenario: „Interleaved Hidden Markov Models“ (IHMMs)

# 10. Erkennung von unterbrochenen Aktivitäten mit Hidden Markov Modellen

## □ IHMM Erweiterung von HMM



- Experimente in einer simulierten RFID Umgebung
- Ergebnisse: IHMM bessere Erkennungsrate als HMMs

J. Modayil, T. Bai, H. Kautz. "Improving the Recognition of Interleaved Activities". Proceedings of the 10th International Conference on Ubiquitous Computing, 2008

# Themenvergabe

- Fragen zu den Themen?
- Welches Thema möchten Sie bearbeiten?
  
- Organisatorisches: Bitte vergessen Sie nicht den zweiten Einführungstermin am 06.05
- E-Mail Liste?