

AKTIONSKLASSEN FÜR HANDLUNGSABLÄUFE IM COMPUTER-GESTÜTZTEN WOHNEN

Obernosterer M¹, Panek P², Mayer P², Neumaier A¹, Zagler WL²

Kurzfassung

Das eHome Assistenzsystem wurde zur Unterstützung allein lebender älterer Menschen entwickelt. Die gesammelten Aktivitätsdaten von insgesamt 18 Monaten in 11 Wohnungen wurden in anonymisierte Form einer weitgehend wohnungsunabhängigen statistischen Analyse unterzogen. Aus der Datenanalyse resultieren Aktionsklassen, mit welchen typische Verhaltensmuster aufgezeigt werden. Aufbauend darauf soll das Expertensystem von eHome durch ein lernfähiges Bayesisches Netzwerk komplementiert werden.

Abstract

The eHome assistance system was developed for supporting older people living alone. The complete activity data resulting from 18 months in 11 flats was subjected in anonymised form to a nearly flat-independent statistical analysis. The data analysis resulted in action classes, from which typical behaviour patterns can be deduced. On their basis, the expert system of eHome will be complemented by a self-learning Bayesian network.

Keywords – Home monitoring, AAL, Bayesisches Netzwerk, EM-Algorithmus

1. Einleitung

Zur Unterstützung alleine lebender älterer Menschen wurde das *eHome* Assistenzsystem für Senioren von einem österreichischen Konsortium [2] entwickelt. Hauptziel war es, das selbstständige Leben von älteren Menschen in der eigenen Wohnung sicherer und leichter zu machen und auch ihre Angehörigen und Betreuungspersonen zu informieren und zu entlasten [8], [17]. Der Prototyp wurde im Hinblick auf die zukünftige praktische Anwendbarkeit als *Embedded System* mit *autonomer Online-Auswertung* konzipiert und so implementiert, dass das System unmittelbar nach der Installation in einer Wohnung *ohne Training* einsatzbereit ist.

Der entwickelte *eHome*-Prototype wurde im Alltagsumfeld erfolgreich erprobt [17]. Der dabei gesammelte Datensatz umfasst insgesamt 18 Monate in 11 Wohnungen von 11 Testpersonen (TP, siehe *Abbildung 2*, rechts) und ist annotiert, d.h. er bietet eine Vergleichsmöglichkeit mit der Datenauswertung.

¹ Fakultät für Mathematik, Universität Wien

² Zentrum für Angewandte Assistierende Technologien (AAT), IGW, Technische Universität Wien

Nach Projektende wurden die bis dahin gesammelten Aktivitätsdaten in anonymisierter Form interdisziplinär analysiert. Der vorliegende Beitrag beschreibt die Herangehensweise und erste Ergebnisse einer mathematischen *Offline*-Analyse [12] durch die Universität Wien. Schwerpunkt ist dabei eine "generische", d.h. weitgehend wohnungsunabhängige statistische Datenanalyse, die möglichst viel Information aus den Daten selbst entnimmt. Der Aufwand zur manuellen Konfiguration eines lernenden Systems, das eine wertvolle Ergänzung und Verbesserung des derzeit in eHome verwendeten Expertensystems darstellen könnte, bleibt so möglichst gering. Der alternative statistische Zugang erlaubt außerdem, die Robustheit der von eHome gelieferten Ergebnisse abzuschätzen. Ziel ist (a) die Anwendung mathematischer Methoden auf die *offline* vorliegenden Daten zur Absicherung der im eHome Projekt erfolgreich angewandten *online* Methoden sowie (b) die *offline* erfolgende Erarbeitung von Methoden, die in zukünftigen Projekten auch zur *online* Analyse (durch entsprechende Erweiterung des eHome-Systems) verwendet werden können.

Der Beitrag gliedert sich wie folgt: Im Abschnitt 2 wird ein Überblick über das prototypenhaft entwickelte eHome-System, seinen Ansatz zur *online*-Analyse und die gesammelten Daten gegeben. Im Abschnitt 3 werden die mathematischen Methoden der *Offline*-Datenanalyse beschrieben, Teil 4 erläutert die ersten Ergebnisse, die im Abschnitt 5 diskutiert werden.

1. 1. Stand der Technik

Die Literatur zu Ambient Assisted Living (AAL) umfasst eine Vielzahl von Berichten von Forschungsprojekten und Prototypen zu Monitoring-Systemen mit ähnlicher Zielsetzung. Die eingesetzten Methoden sind dabei sehr unterschiedlich, von Software Agenten bis Support-Vektor-Maschinen, von reinen Laborerprobungen bis Tests in Alltagsumgebungen [3,4,6,7,14].

2. Das eHome System und die Erprobung im Alltag (Online-Betrieb)

Das eHome-System besteht aus (Abbildung 1) einem ZigBee Netzwerk von Sensoren und Aktuatoren, einer eHome HCU (Zentraleinheit), der lokalen Benutzerschnittstelle (LUI), dem Alarm-Routing-Server (ARS) und der Remote Benutzerschnittstelle (RUI) [11].

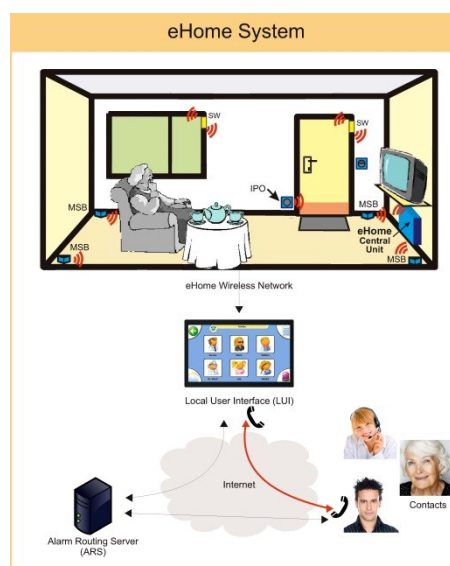


Abbildung 1: eHome Architektur im Überblick

Das Sensornetzwerk von *eHome* verwendet Sensormodule (*Multi-Sensor-Boxen*, MSB) mit mehreren Sensoren: Temperatursensor, IR Temperatursensor, Lichtsensor, Vibrationssensor, Schaltkontakt, PIR Bewegungssensor. Jede MSB sammelt eigenständig die Sensordaten, führt eine *low-level* Signalanalyse und Datenverdichtung durch und überträgt die Daten mit einem Zeitstempel versehen über das drahtlose ZigBee Netzwerk. Die Daten werden nach konfigurierbaren Prinzipien aufgefrischt.

Die HCU ist mit einem Linux basierten Embedded PC aufgebaut und beherbergt den ZigBee Koordinator. Alle Daten werden hier zentral gesammelt und analysiert. Datenbasiert werden verschiedene Algorithmen ausgeführt und im Bedarfsfall zeitnahe Alarme generiert. Es werden sowohl laufend die aktuellen Daten in Echtzeit überwacht und so bereits Ergebnisse innerhalb kurzer Zeit erzielt, als auch stündlich und täglich eine umfassendere Beurteilung der Änderung signifikanter Werte vorgenommen, wodurch wieder Vergleichswerte für die laufende Auswertung und Statusdarstellung gewonnen werden. Die HCU stellt auch den Systemzustand über Webseiten für autorisierten Zugriff zur Verfügung (RUI Remote User Interface) und verfügt über eine Breitbandverbindung.

Ein Expertensystem [9], [10] beurteilt über kontextabhängige Regeln die Alltagssituation des Benutzers und erstellt Statusberichte und kann Alarme auslösen. Die Regeln wurden zusammen mit Experten aus dem Pflegebereich und Nutzern erstellt und berücksichtigen über die selbsttätige Anpassung von Parametern durch Auswertung der Daten sich ändernde Verhaltensweisen. Ein kleiner Kernregelsatz zielt auf ein robustes und schnell installierbares System unabhängig von der individuellen Umgebung zu Hause. Die Lernfähigkeit konzentriert sich auf die Anpassung an sich ändernde Gewohnheiten, die voreingestellten Werte erlauben die Verwendung des Systems direkt nach der Installation in der Wohnung [8].

Eine Besonderheit des *eHome*-Systems stellen die hoch-empfindlichen Vibrationssensoren dar. Diese in den MSBs integrierten Sensoren registrieren kleinste Erschütterungen und können die von einem Sturz ausgehenden Bodenvibrationen feststellen. Durch den Einsatz mehrerer MSBs kann dadurch ein Sturz *online* festgestellt und lokalisiert werden. Details dazu wurde in [16] publiziert.

eHome kommuniziert mit dem Nutzer über ein Touch-screen-basiertes Terminal (Erinnerungen, Bestätigungen für Alarme, Freisprech-Videotelefonie, Informationen über aktuelle Nachrichten und Wetter) [11].

Das *eHome*-System wurde in elf Wohnungen im Alltagseinsatz von elf Damen im Alter von 56 – 82 Jahren (Durchschnittsalter: 73 Jahre) getestet [17]. Drei dieser Tests waren Langzeittests über vier Monate, acht Installationen wurden für jeweils ein Monat getestet. Fünf Tests fanden im AAL Living Lab Schwechat [5], sechs in Wiener Wohnungen unterschiedlichster Größe statt. Die Anbringung der Sensoren erfolgte an strategischen Punkten in den Wohnungen (Küche, Wohnraum, WC, Schlafzimmer) basierend auf dem gesammelten Knowhow und mit dem Ziel, bestimmte Ereignisse möglichst sicher erkennen zu können, z.B.: Anwesenheit in Raum/Wohnung, Benützung Toilette/Bad, Aufenthalt im Bett, Aktivität, Sturz, Gefahr durch Herd.

3. Methoden der Offline Auswertung

Die verfügbaren Rohdatensätze wurden einer mathematischen Offline-Analyse unterzogen. Zielsetzung war dabei, die Untersuchung möglicher Algorithmen sowie Empfehlungen zur

Optimierung der Datensammlung und Aufbereitung, die bei einem zukünftigen verbesserten Prototyp berücksichtigt werden können. Nach Feststellen der vorhandenen Sensoren und der Bereinigung der Rohdaten (insgesamt 5.5 Millionen Zeilen, 11 Einträge pro Zeile) von Fehlerwerten und von Sensoren mit zu kurzer Laufzeit wurde zunächst eine deskriptive Analyse (verschiedene statistische Werte einzelner Sensoren oder Sensortypen, Verteilung der Signale über 24 Stunden und der Zeitintervalle zwischen Signalen) vorgenommen.

Auf Grund der deskriptiven Analyse wurden Grenzwerte für die weitere Analyse definiert und die gegebenen Sensordaten in äquidistante Zeitreihen im 10 Sekunden Abstand umgewandelt (in allen Zeitreihen insgesamt 326 Millionen Einträge). Zur automatischen Klassifikation der Zeitfenster in Aktionsklassen wurde der EM-Algorithmus (*Expectation-Maximization Algorithm* [1]) für Gaußsche Mixturen [15] verwendet. Von den versuchten Methoden lieferte er die am besten interpretierbaren Ergebnisse. Vor der Klassifikation wurde eine Dimensionsreduktion vorgenommen (Hauptkomponentenanalyse oder QR- Faktorisierung), um die Datenfülle mit nur geringem Informationsverlust zu reduzieren.

4. Erste Ergebnisse

Durch ein interaktives Programm ist es möglich, die Daten einer beliebigen Testwohnung in relativ kurzer Zeit (ca. 10 Minuten interaktive Aufnahme und 10 bis 15 Minuten interaktives Rechnen) aufzuarbeiten (Bereinigen, Statistik, äquidistante Zeitreihen, Datenreduktion, Klassifizierung der Zeitfenster, automatische Erzeugung relevanter Tabellen und Abbildungen). Danach können verschiedene Untersuchungen über alle so vorbearbeiteten Wohnungsdaten durchgeführt werden.

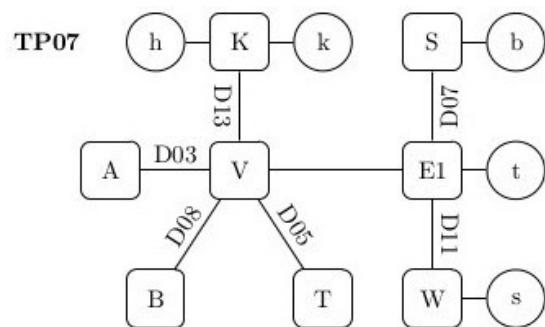
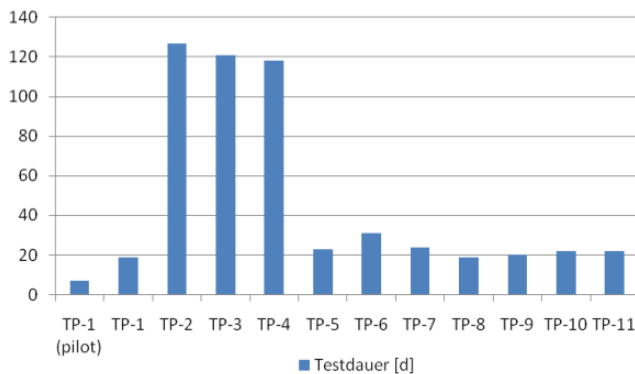


Abbildung 2: Testdauer in 11 Wohnungen, Gesamtdauer: 553 Tage (links), Graph TP-07 (rechts)

Die Topologie jeder Wohnung wurde in einem Graphen dargestellt (vgl. *Abbildung 2*; TP-07). Dem Graphen kann entnommen werden, welche Räume (*eckige Knoten*) es gibt, wie diese miteinander verbunden sind (*lange Kanten*), ob es entlang der Verbindung einen Türkontaktsensor gibt und wo sich die ausgezeichneten Objekte wie Sofa, Bett, Herd etc. (*runde Knoten*) befinden (*kurze Kanten*). Für den Fall, dass die Person sich nicht in der Wohnung aufhält, gibt es in jedem Graphen einen Knoten A (*Abwesend*). Jedem Knoten (Raum oder Objekt) wurde eine bestimmte Anzahl von Sensoren zugeordnet. Durch eine Studie der verschiedenen Grundrisse wurde eine gewisse Anzahl von Räumen und Objekten ausfindig gemacht, die fast alle Wohnungen gemeinsam haben. Für eine wohnungsunabhängige Analyse wurden nur jene Räume und Objekte betrachtet, die dieser gemeinsamen Teilmenge entsprechen (zum Beispiel wurde in *Abbildung 2* das Extrazimmer E1 oder der Balkon BK nicht analysiert).




Abbildung 3: Von oben nach unten sind die ausgewählten Sensoren für Eingang, Herd, Kühlschrank, Küche Tisch usw. bis zum Schlafzimmer, abgebildet.

Die letzte Zeile zeigt die Abfolge der Aktionsklassen. Donnerstag; Testwoche1; Testwohnung TP-07.

Abbildung 3 zeigt als Beispiel einen Tag von Testwohnung TP-07. Der Farbcode stellt automatisch ermittelte Aktionsklassen dar. Diese lassen sich intuitiv interpretieren. Z.B. blau (abwesend): Offenbar verließ die Testperson an diesem Tag zweimal die Wohnung. In der Nacht wechseln sich zwei Klassen ab: rot (ruhiger Schlaf); dunkelblau (unruhiger Schlaf). Nächtliche WC-Gänge werden erkannt – zwischen 0:00 und 1:00 Uhr sowie kurz vor 20:00 und kurz vor 23:00 Uhr (Details siehe *Abbildung 4*). Die Bedeutung der übrigen Klassen kann in einer verbesserten Auflösung erkannt werden. In *Abbildung 4* können wir z.B. beobachten, aus welcher Abfolge von Aktionsklassen sich ein nächtlicher WC-Gang zusammensetzt: rot (ruhiger Schlaf), dunkelblau (unruhiger Schlaf), dunkelgelb (Bewegung im Schlafzimmer), hellgrün (Bewegung: Tisch, Vorzimmer; Vibration: WC), gelb (Licht im WC sowie offene WC-Türe), danach in umgekehrter Reihenfolge zurück. Diese Abfolge entspricht dem Weg, der zurückgelegt werden muss – andere WC-Gänge sind gleich oder zumindest sehr ähnlich aufgebaut. Eine Abfolge von Klassen dieser Art kann als WC-Gang klassifiziert werden.

5. Diskussion

Erste Ergebnisse zeigen, dass eine Datenanalyse fast vollautomatisch Aktionsklassen so definieren kann, dass bestimmte Abfolgen von Aktionsklassen bestimmten natürlichen Verhaltensabläufen (z.B. nächtlicher WC-Gang) entsprechen. Die entwickelte Methodik könnte gut kombiniert werden mit dem bestehenden *eHome*-Expertensystem [8, 10].

Unser Konzept ermöglicht, dass die Datenanalyse direkt nach Installation des Systems in einer neuen Wohnungen angewendet werden kann, mit nur geringfügigen Anpassungen: für jede neue

Wohnung müssen nur die Wohnungstopologie und die Ausstattung der Räume mit Sensoren neu eingestellt werden. Aufbauend auf diesen Wohnungsmodellen arbeiten wir gerade daran, aus den gegebenen Daten die Bewegung der Testperson innerhalb dieses Graphen zu rekonstruieren. Da die Abfolge der Aktionsklassen durch eine Aktivität nicht unbedingt deterministisch festgelegt ist, verwenden wir Bayesische Netzwerke [13], um die Variabilität statistisch korrekt zu erfassen. Wir arbeiten derzeit an robusten Modellen und Trainingsmethoden für solche Netzwerke.

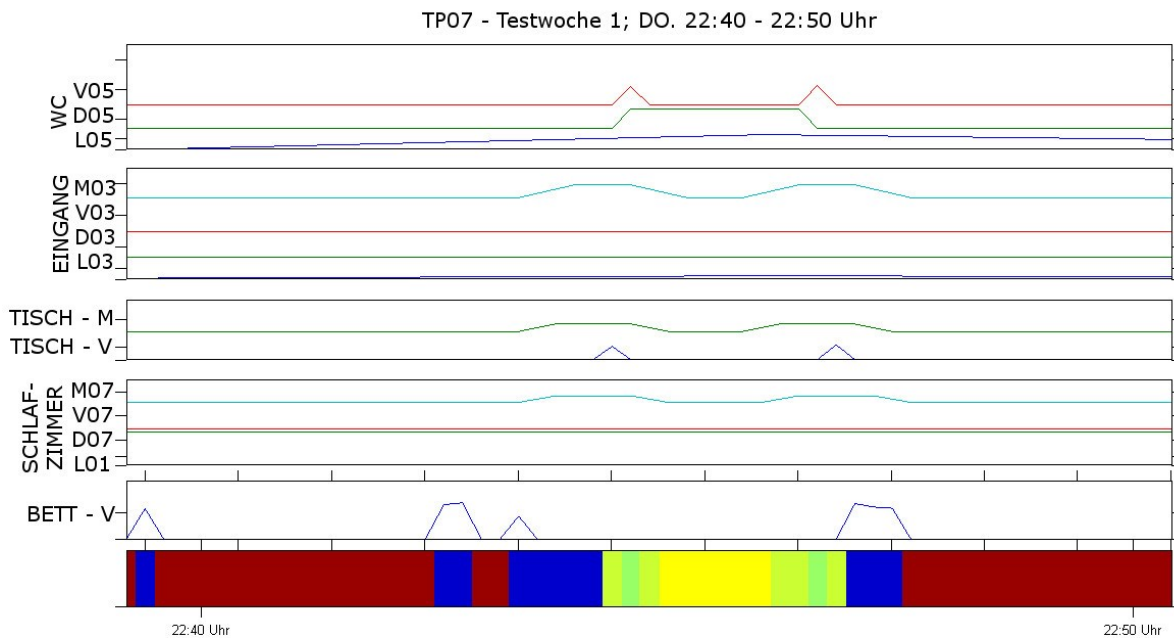


Abbildung 4: Ein nächtlicher Gang zur Toilette; Abgebildet sind die Räume mit Aktivität; Letzte Zeile: Abfolge der Aktionsklassen; Donnerstag, Testwoche 1; 22:40 – 22:50 Uhr; Testwohnung TP-07.

Es ist bemerkenswert, dass diese Einteilung in Aktionsklassen zustande kommt, ohne dass irgendwelche semantische Information vorausgesetzt wurde. Der Supervisor kann sich die aus den Bildern ersichtlichen Aktionsklassen anschauen und im Nachhinein mit einer Interpretation versehen, welche dem System ab dann verfügbar ist.

Wir erwarten, einen Algorithmus zu bekommen, der (basierend auf einem Bayesischen Netzwerk) eine automatische, konsistente und robuste Feststellung des Aufenthaltsorts zu fast jeder Zeit liefert. Die Parameter des Bayesischen Netzwerks sind fix initialisiert, sollten sich aber im Online-Betrieb mit einem Lernalgorithmus zunehmend auf die optimalen Werte für jede individuelle Wohnung einstellen. Aufbauend darauf können dann typische Verhaltenssequenzen aufgezeigt werden, die nach Benennung durch den Supervisor vom System sprachlich artikulierbar sind. Das liefert die Basis für eine spätere Erkennung und ggf. Signalisierung von untypischem Verhalten, sowie für die Konstruktion von Schemata für einen evtl. Dialog mit den Bewohnern.

6. Danksagung

Das Projekt "*e-HOME - Context-Aware and Distributed Embedded System for Assistive Home Technology*" wurde durch das Bundesministerium für Verkehr, Innovation und Technologie gefördert (FIT-IT 815195). Projektpartner: *TU Wien, Ceit Raltec GmbH, Kapsch CarrierCom AG, Treventus Mechatronics GmbH*. Wir danken den an der Erprobung mitwirkenden Personen und den Experten und Expertinnen aus dem Pflege, Betreuungs- und Therapiebereich für ihre Unterstützung.

7. Referenzen

- [1] Dempster, A P, Laird, N M, Rubin, D B. Maximum Likelihood from Incomplete Data via the EM Algorithm. *Journal of the Royal Statistical Society. Series B (Methodological)* 39 (1): 1–38, 1977.
- [2] eHome Webseiten: <http://www.aat.tuwien.ac.at/ehome/e-HomeErgebnisse.html> <http://deutsch.ceit.at/ceit-raltec/projekte/aal---ehome> (letzter Zugriff: 22.1.2013).
- [3] Floeck M, Litz L. Aktivitätsüberwachung in Bestandswohnungen mit einfach nachrüstbarer Basisausstattung. 3. Deutscher AAL-Kongress, Berlin, 2010.
- [4] Hein A, Winkelbach S, Martens B et al. Monitoring systems for the support of home care. *Informatics for Health and Social Care*. 2010; 35:157 - 176.
- [5] Hlauschek W, Panek P, Zagler W L. Involvement of elderly citizens as potential end users of assistive technologies in the Living Lab Schwechat, in PETRA'09, ACM, Corfu, Greece, 2009.
- [6] Kleinberger T, Jedlitschka A, Storf H, Steinbach-Nordmann S, Putz W, Gross A. Notfallerkennung und -prävention: Ergebnisse und Verwertung. 4. Deutscher AAL-Kongress. Berlin: VDE, 2011.
- [7] Marschollek M, Bott OJ, Wolf K et al. Home Care Decision Support Using an Arden Engine - Merging Smart Home and Vital Signs Data. *Stud Health Technol Inform.*, 10th. Congr. on Nursing Informatics, Helsinki, 2009:483-7.
- [8] Mayer P, Panek P. Assessing daily activity of older persons in a real life AAL system, in: *Telehealth 2012*, Innsbruck, Austria, 2012, p. 772-775.
- [9] Mayer P, Panek P. Ein AAL-Ansatz zur Status- und Aktivitätsbeurteilung durch Domainexpertenwissen mit wenigen und nichtintrusiven Sensoren, 4. Deutscher AAL Kongress, VDE, Berlin, 2011.
- [10] Mayer P, Panek P. Erste Ergebnisse einer Status- und Aktivitätsbeurteilung mittels Expertenwissen und wenigen unaufdringlichen Sensoren, 4. Deutscher AAL Kongress, VDE, Berlin, 2011.
- [11] Mayer P, Rauhala M, Panek P. Praxistest des eHome Systems, 4. Deutscher AAL Kongress, VDE, Berlin, 2011.
- [12] Obernosterer M. Mathematische Methoden für computergestütztes Wohnen, Diplomarbeit in Arbeit, Fakultät für Mathematik, Universität Wien, 2013. Online verfügbar auf <http://www.mat.univie.ac.at/~neum/ms/DAobernosterer.pdf> (letzter Zugriff: 19.4.2013).
- [13] Pourret O, Naim P, Marcot B. *Bayesian Networks: A Practical Guide to Applications*. Chichester, UK: Wiley, 2004.
- [14] Spellerberg A, Grauel J, Schelisch L. Ambient Assisted Living – ein erster Schritt in Richtung eines technischsozialen Assistenzsystems für ältere Menschen. *Hallesche Beiträge zu den Gesundheits- und Pflegewissenschaften*. 2009; 8:3-19.
- [15] Titterton D, Smith A, Makov U. *Statistical Analysis of Finite Mixture Distributions*. Wiley, 1985.
- [16] Werner F, Diermaier J, Schmid S, Panek P. Fall Detection with Distributed Floor-mounted Accelerometers, in: *Conf on Pervasive Computing Technologies for Healthcare (PervasiveHealth)*, Dublin, 2011, p. 354-361.
- [17] Werner K, Werner F, Panek P, Hlauschek W, Diermaier J. eHome - Wohnen mit unterstützender Intelligenz, 4. Deutscher AAL Kongress, VDE, Berlin, 2011.

Corresponding Author

Paul Panek

Centre for Applied Assistive Technologies (AAT), Institute for Design and Assessment of Technology (IGW), Vienna University of Technology

Favoritenstrasse 11/187-2b, A-1040 Vienna

Email: panek@fortec.tuwien.ac.at