Technische Universität Chemnitz
Fakultät für Maschinenbau
Professur Arbeitswissenschaft
und Innovationsmanagement

Detektion gestürzter Personen in häuslicher Einsatzumgebung

Tim Wengefeld[1], Benjamin Lewandowski[2], Horst-Michael Groß [3]
[1] tim.wengefeld@tu-ilmenau.de
[2] benjamin.lewandowski@tu-ilmenau.de
[3] horst-michael.gross@tu-ilmenau.de
[123]Technische Universität Ilmenau, Ilmenau/Deutschland

ABSTRACT

Das zuverlässige Erkennen gestürzter Personen, ist ein wichtiges und bislang noch immer nicht befriedigend gelöstes Forschungsthema im Bereich des Ambient Assisted Living (AAL) und der sozialen Assistenzrobotik. Hierbei besteht die Aufgabe darin, unterstützungsbedürftigen Personen ein selbstbestimmtes Leben zu ermöglichen, wobei Gefahrensituationen wie Stürze autonom erkannt werden müssen. State-of-the-Art Verfahren, welche dieses Problem bislang behandeln, verwenden meistens Wearable Devices auf Basis von Beschleunigungssensoren in Kombination mit statisch platzierten Kameras. Aufgrund von kognitiven Einschränkungen der Nutzergruppe und der beschränkten Erfassungsbereiche der Kameras, sind diese Methoden allerdings nur bedingt praxistauglich. Wegen dieser Nachteile, wird ein großes Potential in der Entwicklung von mobilen Assistenzrobotern gesehen, welche neben anderen Assistenzfunktionalitäten auch aktiv nach dem Nutzer suchen, Gefahrensituationen erkennen und Hilfsmaßnahmen einleiten können. Deshalb wurde im Rahmen dieser Arbeit ein Verfahren entwickelt, welches auf Basis von Merkmalen aus 3D Tiefendaten gestürzte Personen erkennen kann. Als Datenrepräsentationsform wird die 3D-Normal Distribution Transform (NDT) verwendet, welche reichhaltige Informationen über die Sturzsituation beinhaltet und gleichzeitig eine echtzeitfähige Verarbeitung erlaubt. Aus diesen NDT-Karten werden poseninvariante 3D-Merkmale extrahiert und anschließend in Sturz/Kein Sturz klassifiziert. Zudem wird ein 3D Umweltmodell verwendet, um gute Klassifikationskandidaten zu bestimmen und Falschklassifikationen zu reduzieren. Für die experimentelle Evaluation des im Rahmen der Arbeit entwickelten Sturzdetektionsverfahrens wurde ein anspruchsvoller Datensatz mit sieben Personen in insgesamt 728 Sturzposen erstellt. Negativdaten ohne Sturzereignisse wurden aus einer wohnungsähnlichen Laborumgebung gewonnen. Im Rahmen des experimentellen Benchmarkings wird das Verfahren auf seine Realwelttauglichkeit überprüft.

Keywords: *Sturzerkennung; mobile Assistenzrobotik; 3D Tiefendaten*

1 EINFÜHRUNG

Abbildung 1: *Assistenzroboter mit Senioren. Aufgenommen im Februar 2015 im Seniorenwohnheim AWO (Erfurt) im Rahmen des SERROGA-Projektes (Gross et al. 2015).*

Quelle: eigene Darstellung (2015)

Das autonome Erkennen gestürzter Personen ist ein wichtiges Teilvorhaben unserer Forschungsprojekte **3DPersA** (Hybride Verfahren zur **3DPers**onenwahrnehmung für die soziale **A**ssistenzrobotik in öffentlichen und häuslichen Einsatzszenarien), **SERROGA**[1] (Gross et al. 2015) und **SYMPARTNER**[2]. Diese beschäftigen sich mit dem praxistauglichen Einsatz mobiler Assistenzroboter für ältere Personen im häuslichen Umfeld (siehe Abbildung 1). Studien zeigten, dass ein Drittel aller über 65-Jährigen mindestens einmal pro Jahr stürzt und die Hälfte davon nicht wieder selbständig aufstehen kann (Lord et al. 2007). Dies zeitnah zu erkennen und Hilfe zu rufen, kann diese Ursache von Todesfällen um 80% verringern, sowie die Notwendigkeit von Krankenhausaufenthalten um 26% reduzieren (Noury et al. 2008). Deshalb gilt die Erkennung von Stürzen als zwingende Voraussetzung, um unser angestrebtes Ziel, der erhöhten Selbstständigkeit im Alter, mittels unterstützender Assistenzsysteme zu erfüllen. Das in diesem Paper vorgestellte Verfahren findet auf einem mobilen Assistenzroboter Anwendung. Dieser steht in Verbindung mit einem Smart-Home-System und soll Gefahrensituationen autonom erkennen und Hilfe herbeiholen. Um die spezifischen Schwierigkeiten in häuslichen Einsatzumgebungen zu behandeln, kommt hierfür ein 3D-Tiefensensor zum Einsatz. Dieser bietet die Möglichkeit, Szenen mit vielfältigen Beleuchtungsvariationen gleichartig zu beschreiben sowie die diversen

[1] http://www.serroga.de/

[2] http://www.sympartner.de/

Erscheinungsformen von gestürzten Personen durch Normalisierung der Position und Orientierung zu vereinheitlichen. Die restliche Arbeit ist wie folgt gegliedert. In Abschn. 2 wird eine Übersicht zum State-of-the-Art gegeben. Abschn. 3 behandelt die Einsatzumgebung und das Zusammenspiel aus Smart-Home-Umgebung und mobiler Roboterplattform. Abschn. 4 beschreibt die verwendete Methodik um gestürzte Personen zu erkennen. Abschn. 5 präsentiert die erreichten Ergebnisse, und Abschn. 6 bietet eine Zusammenfassung und einen Ausblick auf zukünftige Arbeiten.

2 VERWANDTE ARBEITEN

Kommerzielle Lösungen, welche die Problematik der Sturzerkennung behandeln, können in drei Kategorien eingeteilt werden (Mubashir et al. 2013), je nachdem welche Sensoren verwendet werden. Am Körper getragene Sensoren (Wearables), gehen von der Annahme aus, dass Stürze sich von anderen Aktivitäten unterscheidende Bewegungsmuster besitzen. Hierbei kommen Beschleunigungssensoren (Zhang et al. 2006) (Bourke et al. 2010), oder Lagesensoren (Li et al. 2009) zum Einsatz. Aufgrund kognitiver Einschränkungen der Zielgruppe, werden diese Sensoren allerdings häufig vergessen zu tragen oder als stigmatisierend empfunden (Noury et al. 2008) und sind deshalb nur bedingt alltagstauglich. Eine zweite Kategorie kann unter dem Begriff Umgebungssensoren zusammengefasst werden. In (Alwan et al. 2006) wurde ein Sensor beschrieben, welcher Vibrationsmuster im Boden erkennt und Stürze von anderen Aktivitäten unterscheiden kann. In (Toreyin et al. 2007) wurden Schall- und passive Infrarotsensoren verwendet, um Stürze und andere Aktivitäten mittels Hidden Markov Modellen zu klassifizieren. Vorteile dieser nicht-intrusiven Methoden sind die höhere Akzeptanz, sowie eine relativ kostengünstige Bereitstellbarkeit. Aufgrund häufiger Fehlalarme (Mubashir et al. 2013) und Schwierigkeiten, Stürze auf die Knie von Laufen zu unterscheiden (Rimminen et al. 2010), ist diese Herangehensweise aber ebenfalls kritisch zu betrachten. Eine dritte Kategorie besteht aus fest in der Wohnung installierten Kamerasystemen. In (Shoaib et al. 2011) kommt eine Farbbildkamera zum Einsatz, um mittels geometrischer Konstellationen von Füßen, Kopf und Körpermittelpunkt einen Sturz zu klassifizieren. Ähnlich wurde in (Stone et al. 2015) vorgegangen, indem mittels einer statischen Tiefenkamera markante statistische Punkte von Vordergrundobjekten extrahiert wurden und über deren Beschleunigung eine Aussage über den Sturz einer Person getroffen werden kann. Diese Methoden vereinfachen das Problem der Sturzerkennung durch Verwendung von Hintergrundmodellen und der Annahme von dynamischen Objekten als Personen. Dadurch ist es möglich, die Verfahren robuster zu gestalten. Allerdings wird der überwachte Bereich auf den Sichtbereich der Sensoren beschränkt, wodurch Kosten für ein System, welches die komplette Wohnung überwacht, erhöht werden. Um den Kostenfaktor zu reduzieren, ist es möglich, die Sensoren auf einer mobilen Plattform anzubringen, welche den Überwachungsbereich beliebig erweitert. Farbbildbasierte Methoden, die hierfür eingesetzt werden können (Wang et al. 2011) (Lv et al. 2011), behandeln Probleme wie unterschiedliche Posen, Beobachtungspositionen und perspektivische Verzerrungen mit multiplen Modellen, welche von Verfahren inspiriert

wurden, die aufrecht stehende Personen erkennen können. Probleme bilden dennoch die Komplexität der zu erkennenden, gestürzten Personen, da die spezifische Ω-Form der Kopf-Schulter Partie von Personen bzw. typische Symmetrien häufig nicht oder nur verzerrt abgebildet werden. Ein dem unseren Ansatz ähnliches Verfahren, wurde in (Volkhardt et al. 2013) vorgestellt. Dieses arbeitet auf einer Punktwolke, welche durch ein 3D-Gitter heruntergesampelt wurde. Das Problem der stark variablen Posen wird behandelt, indem die Ansichten aller Objekte in einem Referenzkoordinatensystem normalisiert werden. Probleme dieses Verfahrens sind vor allem die Voraussetzung von stark idealisierten Daten. So müssen Punkte, welche von einer Person erzeugt wurden, möglichst vollständig und von anderen Objekten getrennt zusammengefasst (segmentiert) werden. So führen Untersegmentierung (Person verschmilzt mit anderem Objekt) oder Übersegmentierung (eine Person zerfällt in zu viele Teile) grundsätzlich zu einem Sinken der Erkennungsrate. Um diese Probleme zu behandeln, verwenden wir hier als Datenrepräsentation die 3D Normal Distribution Transform (NDT) (Schmiedel et al. 2015), welche bereits im Bereich der dynamischen Roboternavigation zur Erstellung von Umgebungskarten verwendet wird. Vorteile bietet diese vor allem durch die zeitliche Integration von Messdaten, wodurch das Problem der Übersegmentierung durch Sensorrauschen vermindert wird. Außerdem ist es möglich, ein Modell der Umgebung effizient zu beschreiben, wodurch wir das Problem der Untersegmentierung durch Objekte der Wohnung effizient behandeln können.

3 EINSATZSZENARIO UND HARDWAREAUSSTATTUNG

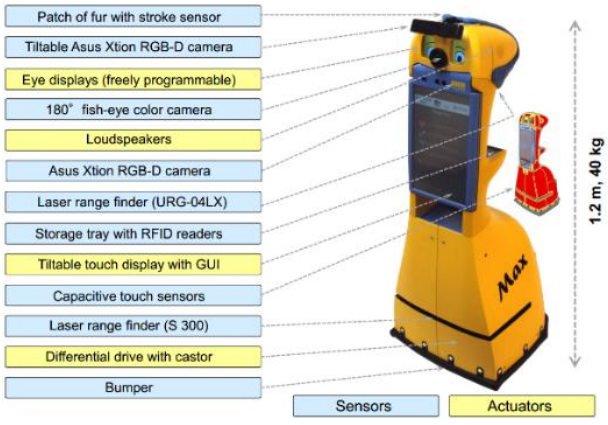

Abbildung 2: Sensorik und Aktuatorik der genutzten Roboterplattform. *Für die Sturzerkennung kommt der nach unten geneigte AsusXtion Tiefensensor zum Einsatz. Für die Nutzerinteraktion während der Notfallbehandlung werden die kapazitiven Touchsensoren, sowie das angebrachte Touchdisplay verwendet.*

Quelle: eigene Darstellung (2016)

Das im Projekt angestrebte Zielszenario sieht die Fusion des Smart-Home-Systems PAUL[3] mit einer autonom agierenden mobilen Roboterplattform vor. Neben dem Bereitstellen verschiedener Services, wie die Erinnerung an Medikamente oder Termine, soll auch eine Erkennung kritischer Situationen sowie deren Notfallbehandlung realisiert werden. Hierfür

[3]http://www.meinpaul.de/

stehen in dem bestehenden PAUL System bereits diverse Sensoren und Methoden zur Verfügung, um eine Inaktivität des Nutzers wahrzunehmen und als kritische Situation zu identifizieren. In der Wohnung verbauten Türkontakte signalisieren dem System, ob ein Nutzer seine Wohnung verlassen hat oder anwesend ist. Infrarot Bewegungssensoren messen innerhalb der Wohnung Bewegungen und signalisieren dem System eine Aktivität des Nutzers und somit seine Unversehrtheit. Dieses Vorgehen ist recht fehleranfällig, da es z.B. schon durch bewegungsarme Tätigkeiten, wie Fernsehen, zu Fehlalarmen kommen kann. Deshalb soll in einem nachfolgenden Validierungsschritt die Notfallbehandlung auf dem Roboter eingeleitet werden. Falls der Nutzer anwesend ist und innerhalb einer bestimmten Zeit keine Aktivität gemessen wurde, beginnt der Roboter eine Suchfahrt durch die komplette Wohnung. Während der Suchfahrt werden kontinuierlich Daten des am Roboter montierten AsusXtion Tiefensensors durch das Sturzerkennungsmodul ausgewertet (siehe Abbildung 2). Falls eine gestürzte Person erkannt wurde, wird über das Smart-Home-System eine Videoverbindung zu einer Kontrollstelle aufgebaut, welche entscheidet, wie Hilfsmaßnahmen einzuleiten sind. In mehrdeutigen Situationen, wie einem auf einer Couch liegenden Nutzer, besteht für den Nutzer die Möglichkeit, durch Berührung der Touchsensoren oder des Displays die Notfallbehandlung abzubrechen.

4 METHODEN

Das vorgeschlagene Verfahren besteht aus 7 Phasen, wie in Abbildung 1Abbildung 3 dargestellt.

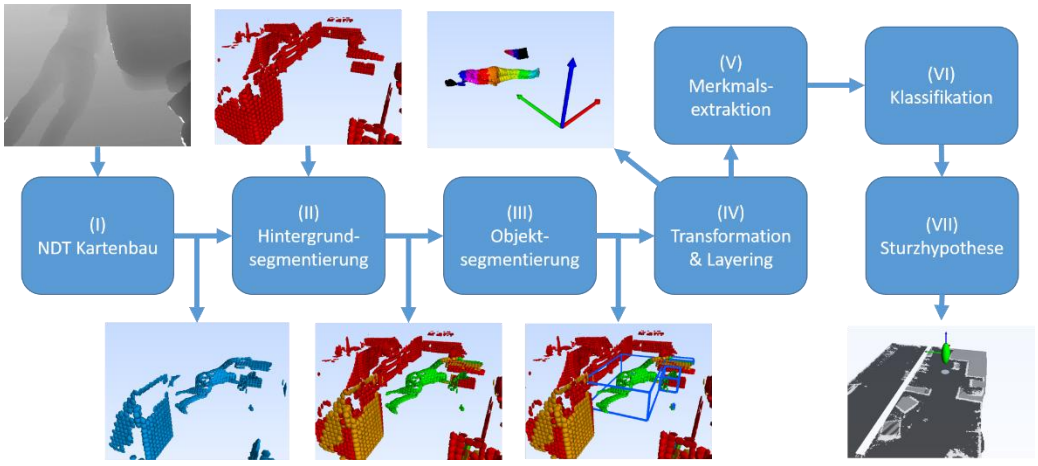

Abbildung 3: Der vorgestellte Ansatz besteht aus 7 sequentiellen Schritten, (I) NDT Kartenbau, bei dem aus dem Tiefenbild eine NDT Karte erstellt wird, (II) Hintergrundsegmentierung, bei der die vorher erstellte NDT Karte in Hintergrund (gelb) und Vordergrund (grün) klassifiziert wird, (III) Objektsegmentierung, bei der Vordergrund NDT Zellen gruppiert werden. (IV) Normalisierung von gruppierten NDT Zellen, (V) Merkmalsextraktion aus diesen Gruppen, (VI) Klassifikation in gestürzte Person und andere Objekte, (VII) Erstellung einer Personenhypothese im globalen Koordinatensystem.
Quelle: eigene Darstellung (2016)

(I) NDT Kartenbau:

Zur Tiefendatenrepräsentation wird das Tiefenbild des Sensors mittels der intrinsischen und extrinsischen Kameraparameter in eine NDT-Karte transformiert (Schmiedel et al. 2015). Der Vorteil dieser Repräsentationsform von 3D Daten besteht darin, dass die einzelnen Datenelemente in einem 3D Gitter gröber aufgelöst und über mehrere Zeitschritte aggregiert werden, um von nachfolgenden Verfahren effizienter behandelt werden zu können. Gleichzeitig bleiben Oberflächeninformationen der ursprünglichen Punkteverteilungen innerhalb einer Gitterzelle erhalten. Die Oberflächeninformationen einer einzelnen NDT-Gitterzelle werden dabei als multivariate Normalverteilung $N(\mu, \Sigma)$ beschrieben, wobei μ dem Mittelwertvektor und Σ der Kovarianzmatrix entspricht. Als Gitterparameter wurde bei unserem Ansatz eine Zellgröße von 5cm x 5cm x 5cm gewählt.

(II) Hintergrundsegmentierung:

In diesem Schritt wird die NDT-Karte, welche von den derzeitigen Sensormessungen erzeugt wird, von einer Hintergrundkarte abgezogen, welche vorher in einer Wohnung ohne Personen aufgenommen wurde. Übrig bleiben dabei NDT-Zellen, welche von typischen dynamischen Objekten, wie Stühlen, Kissen, Haustieren oder Personen erzeugt wurden. Durch diesen Vorverarbeitungsschritt ist es möglich, die Größe der zu klassifizierenden Objektmenge einzuschränken und somit Falschklassifikationen zu reduzieren. Für die effiziente Behandlung dieses Problems wurde eine Nächste-Nachbar-Suche in der Datenstruktur der NDT-Karte verwendet, welche auf einem k-d-Baum basiert. Kann eine NDT-Zelle der Vordergrundkarte einer NDT-Zelle des Hintergrundmodells zugeordnet werden und beträgt deren Abstand mehr als 5 cm, was dem maximalen Lokalisationsfehler des Roboters entspricht (Schmiedel et al. 2015), wird sie als Vordergrund klassifiziert. Alle Vordergrund NDT-Zellen werden anschließend an das nachfolgende Modul weitergegeben.

(III) Objektsegmentierung:

Um die NDT-Zellen zu bestimmen, welche von demselben Vordergrundobjekt erzeugt wurden, wird der Schritt der Objektsegmentierung vollzogen. Zuerst wird mittels des RANSAC Algorithmus (Fischler et al. 1981) die Grundebene geschätzt, wodurch alle NDT-Zellen entfernt werden, welche durch den Boden der Wohnung erzeugt wurden. Alle verbleibenden NDT-Zellen werden durch euklidisches Clustering zu Gruppen $G = \{g_1, \dots, g_M\}$ zusammengefasst, wobei ein Distanzschwellwert von 3 cm verwendet wurde.

(IV) Transformation & Layering

Da Personen partiell von Umgebungsobjekten verdeckt sein können, wird ein teilbasierter Klassifikationsansatz verwendet. Hierfür werden zuerst alle erzeugten Gruppen von NDT-Zellen in eine normalisierte Darstellung transformiert (siehe Abbildung 4). Anschließend werden die NDT-Zellen jeder Gruppe g_j in den Koordinatenursprung verschoben und anschließend um den Differenzwinkel der x-Achse zur Hauptorientierung der Gruppe rotiert. Diese wurde mittels einer Hauptkomponentenanalyse bestimmt, wobei die Hauptorientierung dem ersten Eigenvektor (Achse von Kopf zu Fuß) entspricht. Anschließend wird die Gruppe

g_j entlang der Hauptorientierung in adjazente Layer $L_j = \{l_{1,j}, \ldots, l_{K,j}\}$ fester Größe von 20 cm unterteilt.

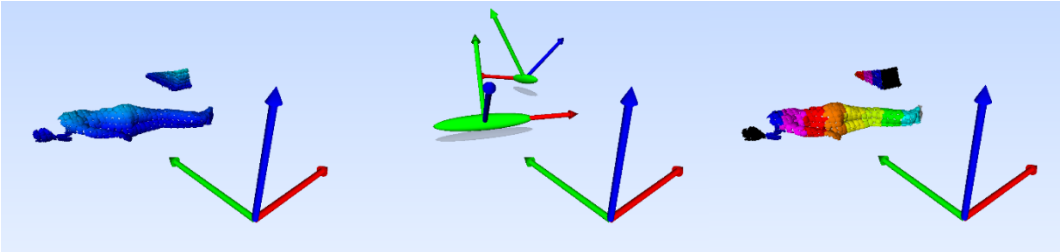

Abbildung 4: Schritte des Layerings. Links: NDT-Karte mit gestürzter Person und Teil eines Sessels. Mitte: Eigenvektoren und Kovarianzellipsoide der einzelnen Gruppen. Rechts: Layer der Gruppen mit unterschiedlichen Farben markiert.

(V) Merkmalsextraktion

Für jeden erzeugten Layer wird nun ein Merkmalsvektor berechnet. Wie in (Volkhardt et al. 2013) beschrieben wurden die besten Klassifikationsergebnisse für Personen aus 3D-Punktwolken mit Merkmalen erreicht, welche als **H**istogram of **L**ocal **S**urface **N**ormals **(HLSN)** (Hegger et al. 2013) bekannt sind. Dabei werden die Oberflächennormale eines Punktes bestimmt, indem eine Ebene in die Punkte der lokalen Nachbarschaft mit einem Radius r gelegt wurde. Der resultierende Normalenvektor wird dann in ein Histogramm für jede Normalenachse (x, y, z) eingetragen. Im verwendeten Ansatz kommen ebenfalls solche Histogramme als Merkmale zum Einsatz. Für die Berechnung der Oberflächennormalen wird allerdings ein alternativer Ansatz angewendet. Dabei werden für jede Kovarianzmatrix $\sum$ einer NDT Zelle ihre Eigenvektoren bestimmt, wobei der Eigenvektor mit dem geringsten Eigenwert die Oberflächennormale repräsentiert. Über die Oberflächennormalen eines Clusters wird nun ebenso wie im bereits erwähnten Ansatz ein Histogramm über die Normalenachsen berechnet und auf eins normalisiert.

(VI) Klassifikation

Um einem erzeugten Cluster ein Label zuzuweisen (positiv: gestürzte Person, negativ: anderes Objekt der Wohnung), verwenden wir das maschinelle Lernverfahren Adaboost, welches auf einem Trainingsdatensatz deskriptive Merkmale auswählt und auf diesen einen Klassifikator trainiert. Als Weak Learner für das Adaboost Verfahren, kommen in unserem Ansatz Entscheidungsbäume zum Einsatz. Werden mehr als zwei Layer einer Gruppe positiv klassifiziert, wird die Gruppe als gestürzte Person angenommen. Verschiedene Parameter wie die Anzahl der Weak Learner und Baumtiefe werden im experimentellen Teil dieser Arbeit behandelt.

(VII) Generierung der Sturzhypothese

Als Ausgabe werden die Zentren der Cluster, welche als positiv klassifiziert wurden, an das Smart-Home-System übertragen. Dieses kann nun den Notfall melden und eine Information

liefern, in welchen Raum der Wohnung eine gestürzte Person vermutet wird, damit zeitnah Hilfsmaßnahmen eingeleitet werden können.

5 EXPERIMENTE

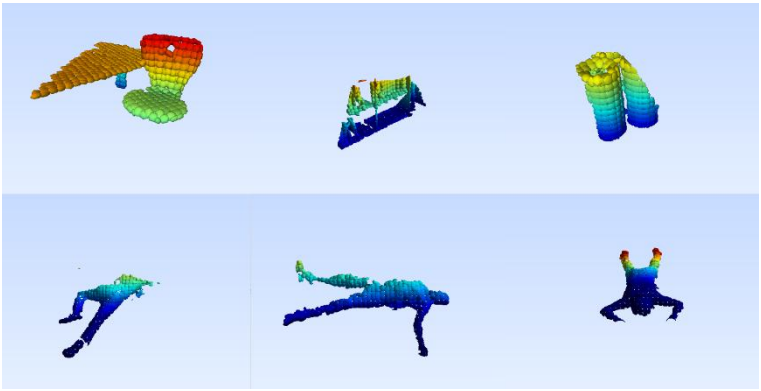

Abbildung 5: Abbildung von Beispielen aus dem Trainingsdatensatz. Obere Reihe Negativdaten aus einer Laborumgebung. Untere Reihe gestürzte Personen.

Quelle: eigene Darstellung (2016)

Evaluierung Detektoren

Um die optimalen Parameter für den verwendeten Klassifikator zu bestimmen, wurde ein Datensatz aufgenommen, welcher 728 im Freiraum gestürzte Personen und 5195 Aufnahmen einer Laborumgebung enthält (siehe Abbildung 4). Als Bewertungsmaß wurde der F-score verwendet, welcher die Genauigkeit (precision) und Trefferquote (recall) mittels des gewichteten harmonischen Mittels kombiniert (siehe **Fehler! Verweisquelle konnte nicht gefunden werden.**).

$$F = 2 * (precision * recall)/(precision + recall)$$

Der Adaboost Klassifikator mit 50 Decision Trees und einer Baumtiefe von 4 konnte bei diesen Experimenten, mit einen F-score von 0,91, die besten Ergebnisse erzielen. Alle weiteren Experimente wurden deshalb mit diesem Klassifikator durchgeführt.

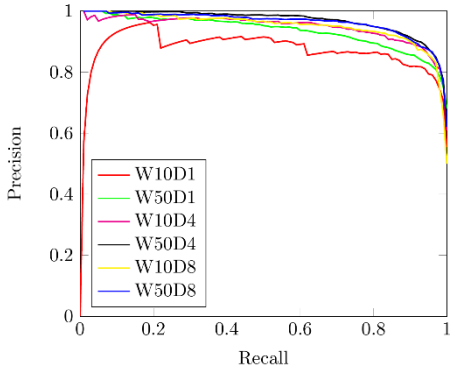

Abbildung 6: Precision Recall Kurve der untersuchten Adaboost Klassifikatoren. Es wurden mehrere Parametereinstellungen untersucht, wobei die Anzahl der Weak Learner (W) mit 10 bzw. 50 variiert wurde. Für die Tiefe der Decision Trees (D) sind verschiedene Einstellungen mit 1,4 und 8 zu entnehmen.

Quelle: eigene Darstellung (2016)

Evaluierung Personensuche

Um die Realwelttauglichkeit unseres Verfahrens zu ermitteln, wurde zusätzlich ein Validierungsdatensatz erstellt. Dieser beinhaltet Suchfahrten, welche in einem Living Lab durchgeführt wurden. Personen und Umgebung des Validierungsdatensatzes sind nicht im Training enthalten gewesen und stellen somit ein Maß für die Generalisierungsfähigkeiten

unseres Verfahrens dar. Als Ground Truth wurde eine 3D Box in den Koordinaten der Umgebungskarte definiert, an der im Datensatz die gestürzte Person enthalten ist. Der Roboter wurde daraufhin an einer Stelle außerhalb des Living Labs positioniert und auf eine autonome Suchfahrt zur Person gesendet. Falls sich die definierte Ground Truth 3D Box im Sichtbereich des Roboters befand und innerhalb dieser eine Person erkannt wurde, wurde dieses Ereignis als True Positive (TP) gewertet. Falls innerhalb der Box keine Person erkannt wurde, ist dies als False Negative (FN) gewertet wurden. Falls eine Personenhypothese außerhalb der 3D Box erzeugt wurde, wurde dies als False Positive (FP) gezählt. In Tabelle 1 können die Ergebnisse dieser Experimente entnommen werden. Die Suchfahrten 1-3 enthielten dabei jeweils eine gestürzte Person und wurden abgebrochen, wenn diese gefunden wurde. Um die maximale Anzahl von Falschklassifikationen pro Suche zu ermitteln, enthielt Suchfahrt 4 keine Person und beinhaltet somit eine Fahrt durch das gesamte Living Lab. Es ist zu sehen, dass durch die verwendete Hintergrundsegmentierung die Erkennungsrate von gestürzten Personen nur geringfügig beeinflusst wird. Die Erzeugung von Falsch Positiven Hypothesen konnte allerdings teilweise um die Hälfte reduziert werden.

	Suche 1		Suche 2		Suche 3		Suche 4	
	ohne II	mit II	ohne II	mit II	ohne II	mit II	ohne II	mit II
TP	119	**131**	**330**	316	**343**	341	0	0
FN	38	**26**	**69**	82	**33**	35	0	0
FP	20	**10**	25	**19**	0	0	76	**47**

Tabelle 1: Ergebnisse der Suchfahrten mit und ohne Hintergrundsegmentierung (II). Die besseren Ergebnisse sind jeweils grün dargestellt.

Evaluierung Laufzeit

Die Laufzeiten des Verfahrens können Tabelle 2 entnommen werden. Mit einer Gesamtlaufzeit von 12,6 ms pro Sensormessung, ist die Echtzeitfähigkeit für den verwendeten AsusXtion Sensor gegeben, welcher eine Bildwiederholrate von 30Hz aufweist.

	(I)	**(II)**	**(III)**	**(IV)**	**(V)**	**(VI)**	**(VII)**	**gesamt**
Laufzeit	10ms	1,3ms	0,9ms	0,4ms	0,16ms	< 0,1ms	< 0,1ms	12,6ms

Tabelle 2: Durchschnittliche Laufzeiten der einzelnen Teile des Verfahrens, pro Sensormessung auf einem 4GHz i7-4790K: *(I) NDT Kartenbau, (II) Hintergrundsegmentierung, (III) Objektsegmentierung, (IV) Normalisierung und Layering, (V) Merkmalsextraktion (VI), Klassifikation, (VII) Personenhypothese.*

6 ZUSAMMENFASSUNG UND AUSBLICK

In diesem Paper wurde ein Algorithmus zur Erkennung gestürzter Personen vorgestellt. Tiefendaten werden in ihre NDT-Form umgewandelt, gruppiert und in Layer unterteilt. Innerhalb dieser Layer werden Merkmalsvektoren mittels Histogrammen über

Oberflächennormalen erzeugt und klassifiziert. Die erzielten Ergebnisse zeigen, dass mit der verwendeten Methodik Personen robust erkannt werden können. Probleme bereiten vor allem noch relativ viele falsch positive Klassifikationen. Diese konnten durch Verwendung einer Hintergrundkarte zwar reduziert werden, allerdings noch nicht in einem befriedigenden Maße. Probleme bereiteten dabei vor allem die Lokalisierung des Roboters, welche durch die spezifischen Schwierigkeiten der Einsatzumgebung, wie das überfahren von Teppichkanten, in ihrer Genauigkeit beeinträchtigt wurde. Diese Probleme zu behandeln steht somit im Fokus unserer weiteren Forschungen zu diesem Thema.

LITERATURVERZEICHNIS

Alwan, M., Rajendran, P. J., Kell, S., Mack, D., Dalal, S., Wolfe, M., & Felder, R. (2006). A smart and passive floor-vibration based fall detector for elderly. *Information and Communication Technologies, 2006. ICTTA'06. 2nd*, 1003-1007.

Bourke, A. K., Van de Ven, P., Gamble, M., O'Connor, R., Murphy, K., Bogan, E., . . . Nelson, J. (2010). Assessment of waist-worn tri-axial accelerometer based fall-detection algorithms using continuous unsupervised activities. *Annual International Conference of the IEEE Engineering in Medicine and Biology*, 2782-2785.

Fischler, M., & Bolles, R. (1981). Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography. *Communications of the ACM*, 381-395.

Gross. H.M. et al. Robot Companion for Domestic Health Assistance: Implementation, Test and Case Study under Everyday Conditions in Private Apartments. in: IEEE/RSJ Int. Conf. on Intelligent Robots and Systems (IROS), Hamburg, Germany, pp. 5992-5999, IEEE 2015

Hegger, F., Hochgeschwender, N., Kraetzschmar, G. K., & Ploeger, P. G. (2013). People detection in 3D point clouds using local surface normals. *RoboCup 2012: Robot Soccer World Cup XVI*, 154-165.

Li, Q., Stankovic, J. A., Hanson, M. A., Barth, A. T., Lach, J., & Zhou, G. (2009). Accurate, fast fall detection using gyroscopes and accelerometer-derived posture information. *Wearable and Implantable Body Sensor Networks*, 138-143.

Lord, S. R., Sherrington, C., Menz, H. B., & Close, J. C. (2007). *Falls in older people: risk factors and strategies for prevention.* Cambridge University Press.

Lv, Q. (2011). A poselet-based approach for fall detection. *Int. Symposium on IT in Medicine and Education*, 209–212.

Mubashir, M., Shao, L., & Seed, L. (2013). A survey on fall detection: Principles and approaches. *Neurocomputing*, 144-152.

Noury, N., Rumeau, P., Bourke, A., O'Laighin, G., & Lundy, J. (2008). A proposal for the classification and evaluation of fall detectors. *Irbm*, 340-349.

Rimminen, H., Lindström, J., Linnavuo, M., & Sepponen, R. (2010). Detection of falls among the elderly by a floor sensor using the electric near field. *IEEE transactions on information technology in biomedicine: a publication of the IEEE Engineering in Medicine and Biology Society*, 1475.

Schmiedel, T., Einhorn, E., & Gross, H.-M. (2015). IRON: A Fast Interest Point Descriptor for Robust NDT-Map Matching and Its Application to Robot Localization. *IEEE/RSJ Int. Conf. on Intelligent Robots and Systems (IROS)*, 3144-3151.

Shoaib, M., Dragon, R., & Ostermann, J. (2011). Context-aware visual analysis of elderly activity in a cluttered home environment. *EURASIP Journal on Advances in Signal Processing*, 1-14.

Stone, E. E., & Skubic, M. (2015). Fall detection in homes of older adults using the Microsoft Kinect. *Biomedical and Health Informatics, IEEE Journal of*, 290-301.

Toreyin, B. U., Soyer, E. B., Onaran, B., & Cetin, A. E. (2007). Falling Person Detection Using Multi-sensor Signal Processing. *Signal Processing and Communications Applications, 2007. SIU 2007. IEEE 15th*, 1-4.

Volkhardt, M., Schneemann, F., & Gross, H.-M. (2013). Fallen Person Detection for Mobile Robots using {3D} Depth Data. *IEEE Int. Conf. on Systems, Man, and Cybernetics (SMC)*, 3573-3578.

Wang, S., Salim, Z., & Leibe, B. (2011). Lying Pose Recognition for Elderly Fall Detection. *Proceedings of Robotics: Science and Systems*, 345-353.

Zhang, T., Wang, J., Liu, P., & Hou, J. (2006). Fall detection by embedding an accelerometer in cellphone and using KFD algorithm. *International Journal of Computer Science and Network Security.*, 277-284.