

Probabilistisch modellierte Blicksteuerung zur Selbstlokalisierung anhand natürlicher Landmarken

Ch. Drexler, C. Frank, J. Denzler und H. Niemann

Universität Erlangen–Nürnberg
Lehrstuhl für Mustererkennung (Informatik 5)
Martensstr. 3, D–91058 Erlangen
WWW: <http://www5.informatik.uni-erlangen.de>

Zusammenfassung Die sichere Selbstlokalisierung autonomer Roboter bildet die Grundlage für deren Einsatz in natürlichen Umgebungen. Um dies in sich ständig verändernden Einsatzgebieten zu gewährleisten, wird ein aktiver Ansatz vorgestellt, der aufgrund von Farbmerkmalen, die aus den Sensordaten einer CCD-Kamera extrahiert werden, Umgebungskarten trainiert und während der Lokalisationsphase eine probabilistisch modellierte Positions- und Blickrichtungssteuerung verwendet. Zum Einsatz kommen Markov Entscheidungsprozesse, mit deren Hilfe Bewegungsfolgen so gewählt werden, dass die Wahrscheinlichkeit für die richtige Lokalisierung anhand der im nächsten Schritt extrahierten Daten maximiert wird. Dabei wird nach einer unsicheren Standortbestimmung diejenige Position angefahren, welche die meiste Information zur Entscheidung über den korrekten Standpunkt beiträgt. Das Verfahren ist daher auch tolerant gegenüber neuen, falsch detektierten und verschwundenen Merkmalen. Anhand von Experimenten in einer realen Flurumgebung wird die Leistungsfähigkeit dieses aktiven Ansatzes mit passiven Methoden zur Selbstlokalisierung verglichen.

1 Motivation

Aufgrund des erwarteten hohen Bedarfs an Dienstleistungspersonal in der Zukunft, beschäftigen sich zahlreiche Wissenschaftler mit der Entwicklung von Dienstleistungs- und Servicerobotern [3, 11]. Die Entwicklung eines autonomen Roboters, der speziell für den Einsatz in Krankenhausumgebungen konzipiert ist, steht im Mittelpunkt des Projekts DIROKOL, in dessen Rahmen neben Verfahren zur robusten Objektlokalisierung (zum Greifen eines Objekts), Objekterkennung (zum Finden des Objekts) und -verfolgung (zur Gestenerkennung) auch Probleme der klassischen Robotik, wie z.B. die relative und absolute Positionsbestimmung [2], untersucht werden.

Diese Arbeit wurde im Rahmen des Projekts DIROKOL erstellt, welches von der Bayerischen Forschungstiftung gefördert wird. Für den Inhalt dieses Artikels sind nur die Autoren verantwortlich.

Dabei stellt die landmarkenbasierte Navigation ein wichtiges Teilgebiet dar [2]. Gerade für die angestrebte Einsatzumgebung innerhalb von Krankenhäusern bietet sich die Verwendung von natürlichen Landmarken unter Verwendung visueller Information aus CCD-Kameras an. Zum Einen entfällt dabei die Notwendigkeit des Anbringens und Ausmessens künstlicher Landmarken und ermöglicht so den Einsatz in unterschiedlichen Umgebungen, ohne diese zu verändern. Zum Anderen ist der Einsatz von aktiven Sensoren, beispielsweise Laserscannern, wie sie bei Reflexionslandmarken benötigt werden, in sensiblen Bereichen der Krankenhäuser nicht gestattet.

In unserem Beitrag stellen wir ein System vor, das in einer Trainingsphase auf Basis von Farbinformation in der Umgebung automatisch Umgebungskarten erlernt. In der anschließenden Lokalisationsphase werden diese effizient extrahiert [6] und zur absoluten Positionsbestimmung benutzt.

Die bisher zur Selbstlokalisierung eingesetzten Verfahren können anhand des Wertebereichs von möglichen Aufenthaltspositionen in kontinuierliche und diskrete Methoden eingeteilt werden. Zu den kontinuierlichen Verfahren gehören z.B. [16] und [14], die eine Selbstlokalisierung durch Kenntnis über die geographische Lage von natürlichen Landmarken diesen Landmarken durchführen. Die 3D-Information aus Lasersensoren vergleicht [7] mit einer, in der Trainingsphase erzeugten, globalen Karte zur Positionsverifikation während der Navigation. Eine ähnliche Karte, generiert aus den Tiefeninformation einer Stereokamera, wird in [19] verwendet. Das Verfahren, das in [4] vorgestellt wird, gehört zu den diskreten Selbstlokalisationsverfahren, da die Aufenthaltswahrscheinlichkeiten für eine festgelegte Menge an möglichen Positionen bestimmt werden. Als Sensoren dienen dabei Laser, die Entfernungen zu Hindernissen liefern und durch den Vergleich mit einer globalen Karte Hinweise auf die eigene Position ergeben.

Das hier vorgestellte diskrete Verfahren basiert auf der in [8] beschriebenen Methode, die partiell-beobachtbare Markov-Prozesse [13] zur Positionsschätzung verwendet. Diese haben gegenüber anderen Verfahren zur statistischen Zustandsschätzung, wie beispielsweise Hidden Markov Modellen [15] oder dem Kalman-Filter [20], den Vorteil, dass sie die Möglichkeit bieten, multimodale Wahrscheinlichkeiten zu handhaben, was für die Verwaltung mehrerer konkurrierender Aufenthaltsorte notwendig ist. Anders als in [8] verwenden wir visuelle Information zur Positionserkennung, da Krankenhausumgebungen wie im Projekt DIROKOL sehr gleichförmig aufgebaut sind und somit Tiefeninformation wenig hilfreich für die Identifizierung von Positionen sind. Treten dennoch Mehrdeutigkeiten auf, so erlaubt es die aktive Erweiterung des Verfahrens, diejenige Position gezielt anzufahren, von der aus diese Ambiguitäten am schnellsten aufgelöst werden kann.

Für die Lokalisation vergleichen wir zwei probabilistische Ansätze. Der erste entspricht einer *passiven* Schätzung, in der das System die gerade verfügbare Information für die Positionsschätzung verwendet. Der zweite Ansatz ist wahr-scheinlichkeitstheoretisch motiviert und steuert den Informationserwerb durch Wahl der Blickrichtung für die Kamera *aktiv* um eine möglichst optimale Positionsschätzung im nächsten Schritt zu ermöglichen [8].

In den experimentellen Untersuchungen zeigen wir, dass die vorgeschlagene aktive Strategie, die in [8] für Lasersensoren vorgestellt wurde, auch auf die Positionsbestimmung mittels visueller Sensoren übertragen werden kann und zu einer Verbesserung im Vergleich zur passiven Strategie führt.

Die Arbeit gliedert sich wie folgt. Der nächste Abschnitt geht auf die Grundlagen der partiell beobachtbaren Markovprozesse ein und beschreibt, wie diese für passive und aktive Selbstlokalisierung einsetzbar sind. Anschließend beschreibt Abschnitt 3 die Testumgebung und verwendeten Merkmale. Die durchgeführten Versuche und erzielten Ergebnisse sind in Abschnitt 4 dargestellt. Abschließend folgt eine Zusammenfassung mit Ausblick.

2 Verfahren

Für die Durchführung von Aufgaben ist es für ein autonomes System essentiell den aktuellen Standpunkt zu kennen. Erst durch dieses Wissen kann im Zusammenhang mit Umgebungskarten eine Routenplanung durchgeführt werden um Zielpositionen anzufahren. Einer der ersten Schritte ist daher die Bestimmung der aktuellen Position bezüglich einer gespeicherten Karte anhand von Merkmalen, sogenannten Landmarken, indem man die in der Umgebung beobachtbaren Merkmale mit den in der Karte abgespeicherten abgleicht.

Neben der Auswahl geeigneter Merkmale ist es vor allem notwendig, Veränderungen der Umgebung in Bezug auf die gespeicherten Daten sicher handhaben zu können. Dies gilt vor allem bei Verwendung von natürlichen Landmarken, da diese nicht in jedem Fall als statisch vorausgesetzt werden können. Desweiteren ist es normalerweise nicht möglich, anhand der Daten, die an einer einzigen Position gesammelt werden, eine eindeutige Positionsschätzung vorzunehmen. Ähnliche Umgebungen lassen sich beispielsweise erst durch Beobachtungen an mehreren Positionen unterscheiden.

Das hier vorgestellte Verfahren verwendet einen aktiven, probabilistischen Ansatz um die dargestellten Probleme handhaben zu können. Der Begriff *aktiv* kommt aus der Bildverarbeitung [5, 1, 18] und bezeichnet die rückgekoppelte Steuerung der Bildaufnahmeparameter, wie beispielsweise Zoom oder Blendeneinstellung, um ein Analyseziel effizient zu erreichen. Im Fall der aktiven Lokalisation ist die Blickrichtungssteuerung in Abhängigkeit von Zwischenergebnissen gemeint, um Ambiguitäten der aktuellen Position aufzulösen.

Da das Verfahren von der Art der Merkmale unabhängig ist, wird an dieser Stelle nicht näher darauf eingegangen. Benötigt wird eine Karte, die für jede mögliche diskrete Position x_i die Wahrscheinlichkeit für das Auftreten eines Merkmalsvektors $p(\mathbf{o}|x_i)$ enthält. Abschnitt 3 erläutert die konkret verwendeten Merkmale und die Kartenerstellung für die Experimente.

Zur aktiven visuellen Selbstlokalisierung wird eine Zufallsvariable X_t definiert, die diskrete Werte $x_i \in \mathcal{X}$ annimmt. Diese Werte, auch *Zustände* genannt, entsprechen den möglichen Positionen in der Versuchsumgebung. Die Wahrscheinlichkeit $p(X_t = x_i)$ repräsentiert somit die Aufenthaltswahrscheinlichkeit des mobilen autonomen Systems an der Position x_i zum Zeitpunkt t . Diese Wahr-

scheinlichkeit wird beeinflusst von der durchgeführten Bewegung a_t des mobilen Systems und dem Merkmalsvektor \mathbf{o}_t , der aus der Beobachtungen an der resultierenden Position bestimmt wird. Die Bewegungen a_t , welche das mobile System von einer diskreten Position in eine andere überführen, erfolgen odometriegesteuert und werden im Folgenden als *Aktionen* bezeichnet.

Es wird angenommen, dass die Wahrscheinlichkeitsverteilung $p(X_t)$ zum Zeitpunkt t nur von der unmittelbar vorherigen Verteilung $p(X_{t-1})$, der Aktion a_{t-1} , die zum Zustandsübergang führt, sowie der Beobachtung \mathbf{o}_t , an der neuen Position, abhängt (*Markov-Annahme*). Somit gilt $p(X_t = x_i | a_0, \mathbf{o}_1, \dots, a_{t-1}, \mathbf{o}_t) = p(X_t = x_i | a_{t-1}, \mathbf{o}_t)$ und wird abkürzend mit $p(X_t = x_i)$ bezeichnet.

Zur Bestimmung der aktuellen Position kommen partiell-beobachtbare Markov-Entscheidungsprozesse (**p**artially **o**bservable **M**arkov-**D**ecision-**P**rocesses, POMDP) zum Einsatz, die in [8] im Detail erläutert sind und deshalb hier nicht näher beschrieben werden. Im Gegensatz zu den Markov-Entscheidungsprozessen [13] kann dabei der aktuelle Zustand selbst nicht beobachtet werden, stattdessen wird eine Beobachtung der Umwelt dazu verwendet, Rückschlüsse auf den Zustand x_i , in dem sie auftrat, zu ziehen.

Die POMDPs verwenden eine initiale Positionsschätzung, die durch Beobachtungen aus der Umwelt und Informationen über die durchgeführte Eigenbewegung, zu jedem Zeitpunkt t aktualisiert wird. Falls zu Beginn der Selbstlokalisierung keinerlei Hinweise auf die aktuelle Position vorliegen, wird initial eine uniforme Verteilung $p(X_0)$ gewählt. Stehen Informationen über die aktuelle Position zur Verfügung, so kann dieses Verfahren auch zur Positionsverifikation oder Positionsverfolgung eingesetzt werden.

Die Aktualisierung der Positionsschätzung entspricht einem zweistufigem stochastischen Prozess, bei dem die erste Stufe den Zustandsübergang, also der Bewegung von einer Position an eine andere, repräsentiert, was durch die Ausführung der Aktion a_{t-1} verursacht wird. Das Resultat ist eine temporäre Zustandsschätzung $p'(X_t)$, die, bedingt durch eine ungenaue Odometrie, fehlerbehaftet ist. In der zweiten Stufe wird durch den Merkmalsvektor der Beobachtung \mathbf{o}_t die Schätzung verbessert und man erhält $p(X_t)$ gemäß

$$p(X_{t-1}) \xrightarrow{a_{t-1}} p'(X_t) \xrightarrow{\mathbf{o}_t} p(X_t) \quad . \quad (1)$$

Die einzelnen Übergänge ergeben sich aus

$$p'(X_t = x_i) = \sum_{x'} p(X_t = x_i | a_{t-1}, X_{t-1} = x') p(X_{t-1} = x') \quad (2)$$

und

$$p(X_t = x_i) = \frac{p(\mathbf{o}_t | X_t = x_i, a_{t-1}) p(X_t = x_i | a_{t-1})}{p(\mathbf{o}_t)} \quad (3)$$

$$= \frac{p(\mathbf{o}_t | X_t = x_i) p'(X_t = x_i)}{p(\mathbf{o}_t)} \quad . \quad (4)$$

Die Wahrscheinlichkeiten in (4) sind unabhängig von a_{t-1} , da es unerheblich ist, über welche Aktion man den neuen Zustand erreicht hat.

Die Wahl der Aktion a_{t+1} für den nächsten Schritt kann auf zwei Arten erfolgen. Führt man die Bewegung der Plattform nach einem festen Schema aus, ohne dass Zwischenergebnisse der Lokalisation in den Steuerprozess einfließen, so spricht man von einem *passiven* Verfahren. Falls man jedoch ein Gütemaß bezüglich der aktuellen Positionsschätzung und den möglichen Aktionen definiert und diejenige auswählt, die das Kriterium optimiert, so spricht man von einer *aktiven* Selbstlokalisierung.

Ein solches Kriterium zur Bewertung ist die Entropie

$$H(p(X_{t+1})) = - \sum_{x' \in \mathcal{X}} p(X_{t+1} = x') \log p(X_{t+1} = x') \quad (5)$$

über der Zustandsverteilung [9]. Sie bietet eine Bewertungsmöglichkeit für die Eindeutigkeit einer Zustandsschätzung da sich bei signifikanter Wahrscheinlichkeit für einen bestimmten Zustand ein Minimum ergibt. Das Maximum würde sich bei Gleichverteilung über alle Zustände ergeben. Da aber sowohl das Resultat der auszuführenden Aktion, als auch die anschließend mögliche Beobachtung unbekannt sind, wird der Erwartungswert der Entropie $E_a(H) = E(H|a)$ nach Ausführung der Aktion a zur Aktionsauswahl herangezogen. Er berechnet sich aus der durchzuführenden Aktion, dem daraus resultierenden Zustandsübergang und allen möglichen Beobachtungen \mathbf{o}_{t+1} für die neue Position. Die ideale Aktion a_t^* ergibt sich somit aus

$$a_t^* = \operatorname{argmin}_{a \in \mathcal{A}} (E_a[H(p(X_{t+1}))]) \quad (6)$$

$$= \operatorname{argmin}_{a \in \mathcal{A}} (E_a[- \sum_{x' \in \mathcal{X}} p(X_{t+1} = x') \log p(X_{t+1} = x')]) \quad (7)$$

3 Versuchsumgebung

Im folgenden wird die Versuchsumgebung beschrieben, in denen die Experimente durchgeführt wurden. Dazu gehört die zur Verfügung stehende Hardware für die Bildaufnahme und zur Lokomotion, die örtlichen Gegebenheiten, die verwendeten Merkmale und die Integration dieser Merkmale in die in Abschnitt 2 beschriebenen Verfahren (POMDP).

3.1 Hardware

Als Lokomotionsplattform wird ein mobiles System des Typs XR4000 der Firma Nomadic Technologies verwendet. Es bietet ein holonomisches Fahrwerk mit drei Freiheitsgraden (X, Y und Rotation) und liefert Odometriedaten an den Steuerprozess. Zur Bildaufnahme wurde eine Farb-CCD-Kamera vom Typ Canon VCC1 verwendet, die über eine Schwenk-Neige-Einheit verfügt. Diese Einheit findet bei den Experimenten jedoch keine Verwendung. Der Bildeinzug und die Datenverarbeitung erfolgt auf einem dedizierten Rechner innerhalb der Plattform der mit zwei PentiumII/300Mhz Prozessoren ausgestattet ist und über

256MB Speicher verfügt. Die Steuerung der Plattform übernimmt ein separater, ebenfalls auf der Plattform montierter, Rechner, der die Steuerbefehle und Odometriedaten über eine Netzwerkschnittstelle mit dem Verarbeitungsrechner austauscht.

3.2 Umgebung und Merkmale

Abbildung 1 zeigt exemplarische Aufnahmen die während der Experimente verwendet wurden. Um die prinzipielle Einsetzbarkeit des Ansatzes zu zeigen, beschränkt sich die Lokalisation auf einen Freiheitsgrad, d.h. die Plattform befand sich an einer Flurkreuzung in einer Büroumgebung und die Aufgabe bestand in der Bestimmung der Blickrichtung, also des Drehwinkels der Rotationsachse, bezüglich der gespeicherten Karte. Ein Verfahren in Richtung der X- und Y-Koordinaten findet nicht statt. Als Merkmale kommen sogenannte *Farbbins*



Abbildung 1. Beispiele des verwendeten Bildmaterials.

zum Einsatz, wie sie auch in [6] Verwendung finden. Sie stellen eine Erweiterung der Farbhistogramme dar, die schon erfolgreich für Objektlokalisierung [17] und -verfolgung [12] eingesetzt wurden. [12] folgend werden als Landmarken Farbhistogrammbins ausgewählt, die neben einer hohen Trefferquote zusätzlich einen eng umgrenzten Bereich im Bild einnehmen, also eine kleine Varianz in der Position aufweisen.

3.3 Integration

Gemäß Abschnitt 2 erfolgt vor Durchführung der Experimente in einem Trainingsschritt der Aufbau der internen Karte. Dazu werden die möglichen Blickrichtungen in 45° Schritten diskretisiert. Je Intervall werden Bilder im 2° -Abstand aufgenommen alle anderen als Trainingsbilder verwendet werden. Aus diesen Trainingsbildern werden diejenigen Farbwerte als Merkmale \mathbf{o}_i benutzt, deren Auftreten über einer Schwelle θ_{num} und deren Varianz unter einer weiteren Schwelle θ_{var} liegen. Aus den Häufigkeiten der auftretenden Merkmale werden mittels einer Maximum-Likelihood-Schätzung die benötigte Verteilung $p(\mathbf{o}_i|X = x_i)$ und die a-priori Wahrscheinlichkeiten $p(\mathbf{o}_i)$ bestimmt.

Unter einer Aktion ist das Verfahren um n diskrete Winkelschritte mittels Odometriedaten zu verstehen. Im passiven Fall erfolgt immer eine Bewegung um einen Schritt in eine vorgegebene Richtung, im aktiven Fall wird die Schrittzahl über die Entropie minimierung gemäß Formel 7 bestimmt.

4 Experimente

Im Folgenden wird die Anwendbarkeit des vorgestellten Verfahrens zur Selbstlokalisierung durch Experimente untersucht. Zunächst soll gezeigt werden, dass farbbasierte Merkmale zur Selbstlokalisierung erfolgreich eingesetzt werden können. Desweiteren wird die Verbesserung der Erkennungsraten bei Einsatz der aktiven Aktionsauswahl untersucht. Es ist zu erwarten, dass aktive und passive Selbstlokalisierung bei genügend großer Menge an verfügbarer Information, ähnlich gute Resultate erreichen. Ebenso benötigt man eine Unabhängigkeit der Erkennungsleistung von kleinen Veränderungen in der Arbeitsumgebung.

Um die Einsetzbarkeit von visueller Information zur Selbstlokalisierung zu testen, wurden 168 Versuche für je drei Bildfolgen durchgeführt. Dazu werden 21 unterschiedliche Sätze von Trainingsbildern verwendet und das mobile System beginnt die Selbstlokalisierung in jedem der acht möglichen Zustände einmal. In Tabelle 1 ist die erreichte Erkennungsrate für diese drei Bildfolgen dargestellt, nach der Anzahl der durchgeführten Iteration aufgeschlüsselt. Hierbei wird mit Iteration die Verbesserung der Zustandsschätzung aus (1) bezeichnet, die durch eine Bewegung und anschließende Beobachtung erzielt wird. Wie erwartet, kann man bei steigender Iterationszahl einen Zuwachs der Erkennungsleistung beobachten, was auf die zusätzlich gesammelte Information zurückzuführen ist.

Iterationen	1	2	3	4	5	6	7	8	9	10
zimmer	0,182	0,278	0,386	0,489	0,551	0,614	0,688	0,750	0,750	0,750
flur1	0,256	0,364	0,494	0,602	0,716	0,835	0,949	1,000	0,994	0,989
flur2	0,307	0,375	0,568	0,688	0,761	0,812	0,881	0,955	0,955	0,949

Tabelle 1. Erkennungsrate der passiven Selbstlokalisierung, aufgeschlüsselt nach Anzahl der Iterationen und Bildserie.

Iterationen	1	2	3	4	5	6	7	8	9	10
zimmer	0,182	0,278	0,398	0,494	0,534	0,580	0,631	0,659	0,659	0,659
flur1	0,256	0,375	0,489	0,580	0,642	0,682	0,727	0,727	0,722	0,710
flur2	0,307	0,409	0,625	0,722	0,795	0,847	0,841	0,835	0,830	0,830

Tabelle 2. Erkennungsrate der aktiven Selbstlokalisierung, aufgeschlüsselt nach Anzahl der Iterationen und Bildserie.

Die passive Selbstlokalisierung verwendet für die Positionsschätzung nur die Beobachtungen, die während des Abfahrens des vorgegebenen Pfads möglich sind. Dagegen werden bei der aktiven Selbstlokalisierung gezielt die Positionen angefahren, welche die aktuelle Zustandsschätzung optimieren. In der ersten Iteration ergibt sich dabei kein Unterschied zur passiven Variante, da ohne Wissen über die aktuelle Position auch diejenige Aktion unbekannt ist, welche in die informationsreichste Position führt. Während der weiteren Iterationen versucht sich das mobile System in diejenigen Positionen zu bewegen, in denen während der Trainingsphase viel Information zur Verfügung stand. Durch den Aufenthalt

in informationsreichen Positionen erreicht die aktive Selbstlokalisierung bereits in der frühen Phase höhere Erkennungsleistung. Dies ist Tabelle 2 zu entnehmen, in der für die Bildfolge `flur2` 5,7% Verbesserung nach der dritten Iteration erreicht werden. Steigt die Anzahl der durchgeführten Iterationen weiter, so steigt bei der passiven Lokalisation auch die Anzahl der eingenommenen Positionen und damit die Menge an unterschiedlichen Beobachtungen. Dagegen wechselt das mobile System während der aktiven Selbstlokalisierung nur zwischen wenigen, meist zwei, informationsreichen Positionen und bekommt dadurch keine neuen Hinweise auf die eigene Position. Dies führt zu einem geringeren Anstieg der Erkennungsrate für höhere Iterationen. Ab welchem Iterationsschritt dieses Verhalten auftritt, ist abhängig von der Informationsmenge der einzelnen Positionen.

Den großen Vorteil der aktiven Selbstlokalisierung in den frühen Iterationen kann man deutlich anhand der Entropie in Abbildung 2 sehen. Hier ist der Verlauf der Entropie für drei Versuchsdurchläufe, die in unterschiedlichen Positionen begonnen wurden, als direkter Vergleich von aktiver und passiver Lokalisation gegeben. Bei passiver Selbstlokalisation muß auf informationsreiche Positionen gewartet werden, ehe die Entropie sinkt. Dagegen begibt sich das System bei aktiver Lokalisation gezielt in diese optimalen Zustände und erreicht deshalb niedrigere Entropiewerte bereits zwei Iterationen früher. Im rechten Teil der




Abbildung 2. links: Sprunghafte Verbesserung der Entropie für drei verschiedene Startpositionen bei passiver Selbstlokalisierung, rechts: sehr schneller Abfall der Entropie bei aktiver Selbstlokalisierung.

Abbildung 2 ist aufgrund der aktiven Selbstlokalisierung ein deutlich schnellerer Abfall der Entropie zu beobachten als im linken Teil, der entsprechende Versuche für passive Selbstlokalisierung zeigt.

Um die Robustheit des Verfahrens gegenüber Veränderungen der Umgebung zu testen, wurden für die Ergebnisse der passiven Selbstlokalisierung in Tabelle 3 Trainingsdaten verwendet, die vor über sechs Monaten entstanden sind (`flur1`). Während dieser Zeit haben sich z.B. die Aushänge an Wänden und die Bestuhlung verändert. Dennoch wird die aktuelle Position für eine der Bildfolgen noch mit über 90% Wahrscheinlichkeit erkannt. Zur Berechnung einer neuen Zustandsverteilung werden ohne Merkmalsberechnung 11 msec benötigt, wobei bei

Iterationen	1	2	3	4	5	6	7	8	9
Erkennungsrate	0,284	0,318	0,477	0,619	0,761	0,835	0,915	0,994	0,955

Tabelle 3. Wahrscheinlichkeiten für richtige Lokalisation bei Verwendung einer sechs Monate alten Karte. Als Trainingsmenge wurden die gleichen Bilder verwendet, mit welchen die Ergebnissen der ersten Zeile in Tabelle 1 erzielt wurden.

aktiver Selbstlokalisierung zusätzlich 19,4 msec zur Bewertung jeder möglichen Aktion nötig sind.

Ausführlichere Versuche zur Selbstlokalisierung sind in [10] zu finden.

5 Zusammenfassung

Diese Arbeit stellt ein Verfahren zur absoluten Selbstlokalisierung anhand von natürlichen Landmarken vor, welches im Rahmen des Projekts DIROKOL entwickelt wurde. Dadurch ist es möglich, mobile Systeme in unterschiedlichen Umgebungen einzusetzen, ohne dass Navigationshilfen angebracht werden müssen.

Das Verfahren gliedert sich in eine Trainings- und eine Lokalisationsphase. Während der Trainingsphase erfolgt die Extrahierung von Merkmalen deren Verteilung mittels einer Maximum-Likelihood-Schätzung automatisch gelernt wird. Als Merkmale kommen Farbbins zum Einsatz, also lokal auftretende Farbcluster, die aus den Sensordaten einer Farb-CCD-Kamera extrahiert werden. Das Verfahren ist jedoch unabhängig vom Merkmalstyp, so dass jede Art von Merkmalen eingesetzt werden kann.

Die Lokalisationsphase verwendet partiell-beobachtbare Markov-Entscheidungsprozesse, die aus einer Folge von Merkmalsvektoren und der zuvor trainierten Merkmalskarte die Wahrscheinlichkeitsverteilung für den aktuellen Aufenthaltsort berechnen. Dabei wird zwischen einer aktiven und einer passiven Vorgehensweise unterschieden. Während bei der passiven Lokalisation auf die Merkmalsakquisition kein Einfluss genommen wird, die Steuerung der Bildaufnahme also unabhängig von den Zwischenergebnissen ist, wählt das aktive Verfahren diejenige Position für die nächste Bildaufnahme aus, deren Informationsgehalt am meisten zur korrekten Lokalisation beiträgt.

Die Ergebnisse zeigen, dass bei zunehmender Information das passive Verfahren besser ist, das aktive jedoch mit wenigen Iterationen im Durchschnitt bis zu 5,6% bessere Erkennungsraten liefert. Vor allem bei wenig Information in der Umgebung der Startposition ergibt sich bei aktiver Lokalisation eine schnelle und sichere Positionsbestimmung, was sich in der rapiden Abnahme der Entropie widerspiegelt.

Nachdem die prinzipielle Leistungsfähigkeit gezeigt ist, wird das Verfahren in zukünftigen Arbeiten auf mehr als einen Freiheitsgrad erweitert. Weiterhin ermöglicht eine Anpassung der gelernten Karte während der Lokalisation die Handhabung starker Änderungen über grössere Zeiträume hinweg.

Literatur

- [1] J. Aloimonos, I. Weiss, A. Bandyopadhyay: *Active Vision*, *International Journal of Computer Vision*, Bd. 2, Nr. 3, 1988, S. 333–356.
- [2] J. Borenstein, H. Everett, L. Feng: *Navigating Mobile Robots*, A K Peters, Wellesley, Massachusetts, 1996.
- [3] W. Burgard, A. Cremers, D. Fox, D. Hähnel, G. Lakemeyer, D. Schulz, W. Steiner, S. Thrun: *The Interactive Museum Tour-Guide Robot*, in *Proceedings of the Fifteenth National Conference on Artificial Intelligence (AAAI'98)*, Madison, Wisconsin, 1998.
- [4] W. Burgard, D. Fox, D. Hennig: *Estimating the Absolute Position of a Mobile Robot Using Position Probability Grids*, *AAAI-96*, 1996.
- [5] J. Denzler: *Aktives Sehen zur Echtzeitobjektverfolgung*, Dissertation, Lehrstuhl für Mustererkennung (Informatik 5), Universität Erlangen-Nürnberg, 1997.
- [6] J. Denzler, M. Zobel: *Automatische farbbasierte Extraktion natürlicher Landmarken und 3D-Positionsbestimmung auf Basis visueller Information in indoor Umgebungen*, in V. Rehrmann (Hrsg.): *Vierter Workshop Farbbildverarbeitung*, Föhringer, Koblenz, 1998, S. 57–62.
- [7] T. Edlinger, G. Weiß: *Exploration, Navigation and Self-Localization in an Autonomous Mobile Robot*, University of Kaiserslautern, 1995.
- [8] D. Fox, W. Burgard, S. Thrun: *Active Markov Localization for Mobile Robots*, Carnegie Mellon University, 1998.
- [9] D. Fox: *Markov Lokalization: A Probabilistic Framework for Mobile Robot Localization and Navigation*, University of Bonn, Institute of Computer Science, 1998.
- [10] C. Frank: *Vergleich probabilistischer Ansätze zur passiven und aktiven Selbstlokalisierung*, Diplomarbeit, Lehrstuhl für Mustererkennung (Informatik 5), Universität Erlangen-Nürnberg, 1999, <http://www5.informatik.uni-erlangen.de/>.
- [11] R. Graf, P. Weckesser: *Roomservice in a hotel*, in *3rd IFAC Symposium on Intelligent Autonomous Vehicles - IAV 98*, Madrid, ES, 1998, S. 641–647.
- [12] B. Heisele, U. Kressel, W. Ritter: *Tracking Non-Rigid Moving Objects Based on Color Cluster Flow*, in *IEEE Computer Vision and Pattern Recognition*, 1997, S. 257–260.
- [13] L. Kaelbling: *Planning and Acting in Partially Observable Stochastic Domains*, *Artificial Intelligence*, Bd. 101, 1998.
- [14] C. F. Olson, L. H. Matthies: *Maximum Likelihood Rover Localization by Matching Range Maps*, in *Proc. of the IEEE International Conference on Robotics and Automation*, 1998, S. 272–277.
- [15] L. R. Rabiner: *A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition*, *IEEE*, Bd. 77, Februar 1989, S. 257–285.
- [16] K. Sutherland: *Landmark Selection for Accurate Navigation*, in *DARPA93*, 1993, S. 485–490.
- [17] M. J. Swain, D. H. Ballard: *Color Indexing*, *International Journal of Computer Vision*, Bd. 7, Nr. 1, November 1991, S. 11–32.
- [18] M. Swain, M. Stricker: *Promising Directions in Active Vision*, CS 91-27, University of Chicago, 1991.
- [19] P. Weckesser, R. Dillmann, M. Elbs, S. Hampel: *Multiple Sensorprocessing for High-Precision Navigation and Environmental Modeling with a mobile Robot*, Institute for Real-Time Computer Systems & Robotics, University of Karlsruhe, 1996.
- [20] G. Welch, G. Bishop: *An Introduction to the Kalman Filter*, UNC Chapel Hill, Department of Computer Science, 1998.