



Hochschule für Angewandte Wissenschaften Hamburg
Hamburg University of Applied Sciences

Studienarbeit

Björn Bettzüge

Foothold Selection for Quadruped Locomotion
Concepts and Visions to Learn a Safety Walk on Rough Terrain

Björn Bettzüge

Foothold Selection for Quadruped Locomotion

Concepts and Visions to Learn a Safety Walk on
Rough Terrain

Studienarbeit eingereicht im Rahmen des Seminars *Anwendungen 1*
im Studiengang Master Informatik
am Department Informatik
der Fakultät Technik und Informatik
der Hochschule für Angewandte Wissenschaften Hamburg

Gutachter: Prof. Dr. Gunter Klemke
Prof. Dr. Kai v. Luck

Betreuender Professor : Prof. Dr. Ing. Andreas Meisel

Abgegeben am 29.02.2012

Björn Bettzüge

Thema der Studienarbeit

Foothold Selection for Quadruped Locomotion
Concepts and Visions to Learn a Safety Walk on Rough Terrain

Stichworte

Vierbeinige Fortbewegung, Robotik, Exterozeption, Propriozeption, Reinforcement Learning

Kurzzusammenfassung

Vierbeinige Roboter haben Vorteile in unsicherem und unebenem Gelände und böten somit einen erheblichen Nutzen in Katastrophen- oder Erkundungseinsätzen. Die aktuellen Forschungen dieser Arbeit befassen sich mit der Frage, wie sicher, im Sinne der Standfestigkeit, die Bodenbeschaffenheit für einen laufenden Roboter ist. Wir betrachten statische oder quasi-statische Fortbewegung, in denen entweder der Center of Gravity bzw. der Zero Moment Point immer im Stabilitätspolygon gehalten wird. Die Aufgabe besteht darin, bei gegebenen Standbeinen einen geeigneten Trittunkt für das Schwungbein zu finden.

Björn Bettzüge

Title of the paper

Foothold Selection for Quadruped Locomotion,
Concepts and Visions to Learn a Safety Walk on Rough Terrain

Keywords

Quadruped Locomotion, Robotic, Exteroception, Proprioception, Reinforcement Learning

Abstract

Quadruped robots have advantages in uncertain and rough terrain, and thus would provide a significant benefit in disaster or exploration missions. The current research of this paper deals with the question of safety and stability of the soil for a running robot. We consider static or semi-static locomotion, in which either the center of gravity or the Zero Moment Point is always kept in the stability polygon. The task is to find a suitable tread position for the swing leg, by given footholds.

Inhaltsverzeichnis

1	Einleitung	1
1.1	Motivation	1
1.2	Zielsetzung	2
2	Überblick	3
2.1	Forschungsrelevanz	3
2.2	Relevante Technologien	4
2.2.1	Maschinelles Lernen	5
2.2.2	Merkmalsgewinnung	6
3	Ausblick	8
3.1	Lösungsansatz	8
3.2	Risiken und Chancen	9
4	Zusammenfassung	10
	Literaturverzeichnis	11
	Anhang A	i

1 Einleitung

Das Projekt AMEE¹ hat zum Ziel, einen vierbeinigen Laufroboter für den Search & Rescue Einsatz zu entwickeln. Ein solches System hat vielfältige Steuerungs- und Analyseaufgaben zu bewältigen, die zudem erschwerend in rauen Umgebungen wie zerstörten Gebäuden und Katastrophengebieten funktionieren müssen. Der Lösungsansatz des von Studenten der HAW Hamburg initiierten Projekts zur Bewältigung der hohen Mobilitätsansprüche von USAR²-Robotern ist ein *Quadruped Rough Terrain Robot*, wobei es sich um einen vierbeinigen, (semi-)statischen Laufroboter handelt [Ruh11] [Ruh12].



Abbildung 1.1: Vision AMEE in Ruine

1.1 Motivation

Roboter mit Beinen bieten die Möglichkeit, in sehr anspruchsvollem Gelände zu navigieren und sind potentiell in vielen Situationen einsetzbar. Jedoch gibt es eine Vielzahl von Herausforderungen, damit das System mit unterschiedlichsten Untergründen und Hindernissen unter Berücksichtigung der mechatronischen Einschränkungen und Ungenauigkeiten zurechtkommt. So wird beispielsweise ein flexibles Schreit-Muster benötigt, das auch on the fly beliebige Stand- und Schwungbeine auswählt. Außerdem ist die Balancekontrolle unter anderen wegen der Abrutschgefahr entscheidend. Ein alleiniges Vertrauen auf ein stabiles Gehmuster kann also nicht ausreichen, vielmehr ist die Fußstellungs-Auswahl für maximale Robustheit und Geschwindigkeit entscheidend.

Relativ wenige Projekte beschäftigen sich mit Gehen auf unebenem Gelände sondern beschränken sich meist auf relativ flaches Gelände, eine Domäne, in der Radsysteme eindeutig überlegen sind. Nichts desto trotz hat es in letzter Zeit einige Fortschritte in diesem Bereich gegeben, auch wenn ein großer Teil dieser Arbeiten unter der Annahme betrieben wurden, dass entweder der Roboter vollständiges Wissen über seine Umwelt besitze oder seine Umgebung nur im angemessenen Rahmen uneben sei, so dass mit nur geringen Wahrnehmungen navigiert werden kann. Eine unrealistische Annahme in vielen wirklichen Domänen.

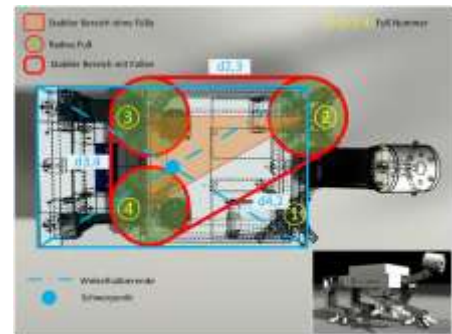
¹ AMEE: Autonomous Mapping, Exploration and Evasion; nicht geschütztes Akronym aus [Hof00]

² USAR: Urban Search And Rescue

1.2 Zielsetzung

Die aktuellen Forschungen dieser Arbeit befassen sich mit der Frage, wie sicher, im Sinne der Standfestigkeit, die Bodenbeschaffenheit für einen laufenden Roboter ist. Wir betrachten statische oder quasi-statische Fortbewegung, in denen entweder der Center of Gravity (COG) bzw. der Zero Moment Point (ZMP³) immer im Stabilitätspolygon gehalten wird. Die Aufgabe besteht darin, bei gegebenen Standbeinen einen geeigneten Trittspunkt für das Schwungbein zu finden. Die gewählte Trittposition muss:

- Rutschen auf Gelände minimieren
- Nicht zu Kollisionen mit der Umgebung führen
- Den Fortschritt Richtung Ziel maximieren
- Innerhalb der kinematischen Reichweite des Roboters sein
- Dazu dienen, die Fläche des Stabilitätspolygons für maximale Stabilität zu maximieren



Meist stehen diese Ziele in Konflikt zueinander, und müssen gegenseitig abgewogen werden. **Abbildung 1.2: COG und Stabilitätspolygon**

Da man diverse und verschiedenste Bodentypen bewerten müsste, ist es ein naheliegender Ansatz, dies dem Roboter durch ein auf Erfahrungen basiertes Lernverfahren beizubringen, beispielsweise Reinforcement Learning [Sut98], sodass das System dazu befähigt wird das umliegende Terrain bezüglich der Laufeigenschaft zu klassifizieren beziehungsweise zu bewerten und mittels des Laufverhaltens bei den umgesetzten Schritten die Schätzungen optimiert.

Als Grundvoraussetzung und eigentliche Herausforderung für ein solch lernendes System muss eine Modellierung mit geeigneten noch zu identifizierenden physikalischen und optischen Merkmalen entworfen werden, die es gilt durch passende Sensoren zu gewinnen und zeitnah sowie Ressourcen schonend zu analysieren sind.

³ ZMP: Punkt, an dem Summe aller Drehmomente Null ist; Berücksichtigt somit auch Beschleunigungen.

2 Überblick

Der Bereich der autonomen Robotik umfasst mehrere Forschungsfelder wie den eher mechatronisch geprägten Bereich der Konstruktion, Steuerung und Sensorik, etabliert durch industrielle Roboter oder der Computer Vision, die sowohl in der industriellen Produktion als auch in verschiedensten Sicherheitssystemen und Webdiensten Anwendung findet. Das Verhalten eines Roboters dagegen ist seit Jahrzehnten Gegenstand der Artificial Intelligence.

Als grundlegenden Einstieg empfiehlt sich das Buch „Handbook of Robotics“ [Bru08], das einen umfangreichen Überblick zur Thematik und zu gängigen Technologien bietet. Darüber hinaus werden Ergebnisse aus der Roboterforschung auf den jährlichen IEEE Konferenzen wie „Robotics and Automation“ (ICRA) oder „Intelligent Robots and Systems“ (IROS) veröffentlicht. Zum Teilgebiet des Maschinellen Lernens seien weiterhin die ICMLA und ICMLC genannt. Aus der Springer Presse empfehlen sich die Magazine „KI – Künstliche Intelligenz“, „Autonomous Robots“, „Artificial Intelligence Review“ und „Machine Learning“.

2.1 Forschungsrelevanz

Obwohl in den letzten zwanzig Jahren eine Vielzahl mechanischer Konzeptstudien zur schreitenden Roboterfortbewegung durchgeführt wurden und Honda bereits Mitte der 90'er Jahre medienwirksam den Zweibeiner ASIMO vorstellte [Hon07], ist das autonome Gehverhalten prinzipiell in der Regel noch nicht zufriedenstellend umgesetzt und weiterhin Gegenstand der aktuellen Forschung. Vergleichend zum Projektrahmen dieser Arbeit, AMEE, werden folgend einige Roboter vorgestellt, die den aktuellen Stand der Technik repräsentieren.

BigDog

BigDog ist ein großer, dynamischer von Boston Dynamics hergestellter Vierbeiner. Er ist bis heute bei weitem der beeindruckendste Roboter, der mit unwegsamem Gelände umgehen kann, wobei die meisten Details über Gestaltung und Steuerung unveröffentlicht bleiben. Einige der bei BigDog verwendeten Kontrollerprinzipien basieren wahrscheinlich auf der Arbeit aus den 1980er und 90er Jahren von Marc Raibert und seinen Schüler am MIT. Der Kontroll-Ansatz für BigDog stützt sich offensichtlich auf die Regelung der Kräfte und Haltung des Roboters. BigDog ist sehr dynamisch und

hat bewiesen, dass er durch bewusste Platzierung der Füße und Körper-Lageregelung mit erheblichen Störungen umgehen kann. Allerdings ist BigDog noch weitgehend blind für kommendes Gelände und reagiert scheinbar weitgehend reflexartig, um dynamisch das Gleichgewicht zu halten. [Rai08]

LittleDog

Der ebenfalls von Boston Dynamics stammende LittleDog ist ein vierbeiniger Roboter, entwickelt für die Erforschung des Erlernens von Fortbewegung („Learning Locomotion“). Wissenschaftler an führenden Institutionen nutzen LittleDog, um die grundlegenden Beziehungen zwischen motorischem Lernen, dynamischer Kontrolle, Wahrnehmung der Umwelt und geländegängige Fortbewegung zu sondieren. LittleDog wird am MIT, Stanford, Carnegie Mellon, USC, Uni. Pennsylvania und IHMC als Teil eines aus DARPA-Mitteln finanzierten Programms für zukunftsweisende Robotik verwendet. LittleDog hat vier Beine, jeweils von drei Elektromotoren angetrieben. Der integrierte Computer erledigt Sensorik, Aktor-Steuerung und Kommunikation. Die Sensoren des LittleDog messen Gelenkwinkel, Motorströme, Körperorientierung und Fuß- / Bodenkontakt. Steuerungsprogramme greifen auf den Roboter durch die Boston Dynamics Robot API zu. [Kal11] [Reb08]

ARAMIES

Das ARAMIES-Projekt vom Bremer DFKI [Hil06] beschäftigte sich mit der Entwicklung eines Laufroboters, der in schwierigem Gelände autonom operieren kann. Einsatzbereiche sollten z.B. Canyons und Krater auf dem Mond oder Mars sein. Das Projekt „ARAMIES“ verwendete ein Laufsystem mit elektrischen Antrieben und versuchte einen „biologischen Controller“ umzusetzen. Es wurden aber feste Laufmuster (Walking Gaits) verwendet, die nach Erfahrungen aus dem DARPA-Programm „Learning Locomotion“ [Reb08] [Est05] nicht immer vorteilhaft sind aber im Vergleich zur üblichen modellbasierten Robotersteuerung den nötigen Rechenaufwand zugunsten hoher Energieeffizienz stark minimiert. Das Projekt ARAMIES wurde 2007 eingestellt und durch das Folgeprojekt SPOT ersetzt.

Durch die vielen Veröffentlichungen des DARPA Forschungsprogramms „Learning Locomotion“, orientiert und vergleicht sich das Projekt AMEE vorrangig an diesen Arbeiten. Zurzeit gibt es kein kommerziell genutztes Laufsystem.

2.2 Relevante Technologien

Folgende Technologien werden im Rahmen dieser Arbeit evaluiert:

2.2.1 Maschinelles Lernen

Lernfähigkeit und Intelligenz werden meist in unmittelbarem Zusammenhang gesetzt und so ist maschinelles Lernen auch eines der ältesten Themen der KI. Grundsätzlich ist Lernen wohl die Fähigkeit des Systems, aufgrund von Erfahrungen die Leistung zu verbessern oder das Wissen zu mehren. In dieser Arbeit geht es konkret um die Fähigkeit, die in unmittelbarer Umgebung liegende Bodenbeschaffenheit nach Aspekten der sicheren Mobilität zu beurteilen und diese Fähigkeit kontinuierlich weiter zu entwickeln. Eine weit verbreitete Methode für Klassifizierungsaufgaben ist das statistische Lernen von Modellen anhand von Beispieldaten. Neuronale Netzwerke (NN) sind in diesem Bereich eine etablierte Technik, auch wenn die Erstellung eines guten Netzes eher auf Erfahrung und Probieren basiert, als auf Formalien oder Paradigmen. Bei wahrscheinlichkeitsverteilten Darstellungen bietet sich die Bayes'sche Kombinatorik an. Ein weiteres, in den letzten Jahren an Beliebtheit stets zugenommenes, Lernverfahren ist das Reinforcement Learning, welches auf Markov-Entscheidungsprozesse (eng.-kurz: MDP) basiert. Durch ein verstärkendes Signal (Belohnung/Bestrafung) auf eine Aktion, lernt das System in welchem Zustand welche Aktion die vielversprechendste ist.

Statistisches Lernen wie unter anderem Bayes-Lernen und NN werden häufig bei Computer Vision und in der Robotik verwendet. Insbesondere Neuronale Netze dienen zudem oftmals als Hilfsmittel oder Ergänzung für andere Verfahren in der KI. In einer Trainingsphase werden Probedaten und die zugehörige Klassifizierung (das gewünschte Ergebnis) angelegt. In einer Testphase wird die Klassifizierungsqualität mit anderen Daten überprüft bevor das NN schließlich produktiv eingesetzt wird. Die Ausbildung des NN besteht in der Anpassung der Gewichte in Abhängigkeit der Abweichung vom gelieferten Ausgangssymbol zum gewünschten Ergebnis (überwachtes Lernen). Die Herausforderung bei NN besteht zum einen in der Wahl geeigneter Parameter (Anzahl Knoten und Schichten, Schwellwerte, etc.) und insbesondere bei der Menge und Qualität der Trainings- und Testdaten, sodass eine gute aber nicht zu hohe Generalisierung und auch keine Überanpassung des gelernten Modells entsteht. NN können im Gegensatz zu Bayes-Lernen online genutzt werden.

Beim Bayes-Lernen wird die Wahrscheinlichkeit eine Hypothese mittels der Bayes-Regel berechnet: Aufgrund beobachteter Effekte, wird zurück zu versteckten Ursachen kombiniert. Dazu dienen Kausalregeln, die die Wahrscheinlichkeiten eines Effekts unter der Bedingung einer Ursache spezifizieren ($P(E|C)$). Mit der Bayes-Regel ist das die Lösung von:

$$P(C|E) = \frac{P(E|C) \cdot P(C)}{P(E)}$$

Das Problem hierbei ist es, die potentiell hohe Anzahl bedingter Wahrscheinlichkeiten zu spezifizieren, was bei n Ereignissen hat dies eine Komplexität von $O(2^n)$. Eine früher Lösungsansatz dazu waren Bayes-Netze⁴. Bekannte Varianten des Bayes-Lernen sind das Maximum-Likelihood-Schätzverfahren (ML) und Erwartungsmaximierung (EM). Sie sind einfach zu implementieren und haben einen mittleren Rechenaufwand [Her08].

Ein unbeaufsichtigtes Lernverfahren ist Reinforcement Learning. Der Roboter führt auf seine Umwelt eine Aktion (action a) aus und erhält darauf den Folgezustand (state s) und eine Belohnung (reward r). Das Verfahren ermittelt daraus die beste Strategie π^* (policy $\pi: s \rightarrow a$), um ein bestimmtes Ziel zu erreichen beziehungsweise den Gewinn zu maximieren. Diese Idee basiert auf Markov-Prozesse, bei denen der Folgezustand nur vom aktuellen Zustand und der Aktion darauf abhängt. Auf viele Prozesse oder Modelle trifft dies zwar nicht zu, doch lassen sie sich oftmals hinreichend gut dahin abstrahieren. Das System versucht die Value-Funktion V , die ein Maß der zu erwartenden Gesamtbelohnung darstellt, zu maximieren. Grundlage dafür ist die Bellmann-Gleichung:

$$V^{\pi^*}(s) = \max_a \left[r(s, a) + \gamma \sum_s P(s'|s, a) V^{\pi^*}(s') \right]$$

Hierbei ist γ ein Discountfaktor, um künftige geschätzte Belohnungen abzuschwächen, $r(s, a)$ die aktuell von der Umwelt gelieferte Belohnung und $P(s_{t+1}=s \mid s_t, a_t)$ eine Zustandsübergangswahrscheinlichkeit. Es gibt mehrere Varianten zur Berechnung der optimalen Strategie, die weitest verbreiteten sind Q-Learning und SARSA- λ . Die grundlegenden Verfahren gehen von einem diskreten Aktionsraum und vor allem, aus rechnerischer Sicht, von einem relativ kleinen Zustands-Aktions-Raum aus, da der Aufwand exponentiell mit der Dimension des Raums steigt. Um dem entgegen zu wirken, setzt man zunehmend für die Werte-Funktion V , bzw. Q , Funktionsapproximationen mittels Gradientensteigungsverfahren oder Neuronale Netze ein.

Probabilistische Verfahren haben sich vielfältig etabliert, insbesondere dort, wo eine Modellierung der Welt entweder zu komplex oder schlichtweg aufgrund zu vieler Unsicherheit nicht adäquat möglich ist.

2.2.2 Merkmalsgewinnung

Optische Verfahren

Eine Methode, 3D Tiefeninformationen von der Umgebung zu erhalten, ist der Einsatz von Time-of-Flight Kameras, auch als PMD-Sensor bekannt, bei der die Laufzeit von Lichtpulsen gemessen wird, die auf eine komplette Szene emittiert werden, typischerweise mit einer Auflösung von 200×200

⁴ J. Pearl: Probabilistic Reasoning in Intelligent Systems (Morgan Kaufmann, San Mateo 1988)

Pixel. Allerdings sind die hohen Kosten dieser Sensoren ein Nachteil und ein kompletter 360°-Scan kann mehrere Minuten dauern und produziert nicht unerhebliche Datenmengen.

Eine etablierte und sehr viel günstigere Technik, 3D-Modelle von Objekten zu generieren, ist der Laser-streifenscan. Dabei wird ein Laserstreifen auf das, sich auf einem drehenden Teller befindliche, Objekt projiziert und von einer (IR-)Kamera aufgenommen. Aufgrund des bekannten Winkels und Abstands zwischen Sensor und Kamera, lässt sich aus dem 2D-Bild durch Triangulation die Tiefeninformation konstruieren. Liang Lu et al. von der Florida State University [LuL09] demonstrierten, wie diese Technik auch zur Bodenklassifikation für autonome Bodenfahrzeuge genutzt werden kann, indem eine Ortsfrequenz- und Texturanalyse (siehe auch [Gon02], [Har92]) ausgeführt und über ein Probabilistisches Neuronales Netz klassifiziert wird.




Abbildung 2.1: Geometrische Konfiguration eines Laserstreifenscanners. [LuL09]

Eine Schätzung oder Beurteilung der vor dem Roboter liegenden Bodens, könnte wie bei dem Projekt von Liang Lu et. al. mittels einer Kombination aus Laserscan und IR-Kamera geschehen. Während sie mittels eines PNN wieder den Bodentyp klassifizieren, sollte im AMEE-System die Mobilitätseigenschaft klassifiziert werden (Zustand s) und als Eingang einer Schätzfunktion $V(s)$ dienen. Im Einsatz dieses Systems auf einem nicht statischem Fahrzeug, dem gehenden Roboter, im Gelände, ist allerdings mit erheblichen Schwierigkeiten zu rechnen, was Kalibrierung und meteorologisch bedingte Messungenauigkeiten angeht.

Propriozeption

Propriozeption ist eine Eigenwahrnehmung der Körperpose und –bewegung im Raum, letzteres auch als Odometrie bekannt. Umgangssprachlich beurteilt man bei der propriozeptiven Analyse, wie sich ein Schritt „anfühlt“. Typische Kenndaten bei einem laufenden System sind Druck am Endeffektor sowie Drehmomente und Stromaufnahme an den Gelenkantrieben über die Zeit. Die Kraftverteilung variiert je nach Bodenbeschaffenheit charakteristisch, insbesondere die Varianz, Kurtosis und Verzerrung dieser Daten über ein Zeitintervall. Ein Seouler Forscherteam [Kim10] demonstrierte für ein einzelnes Roboterbein, wie die Analyse der Propriozeption zur Bodenklassifizierung genutzt werden kann.



Abbildung 2.2: Versuchsaufbau – Propriozeption eines Beins. [Kim10]

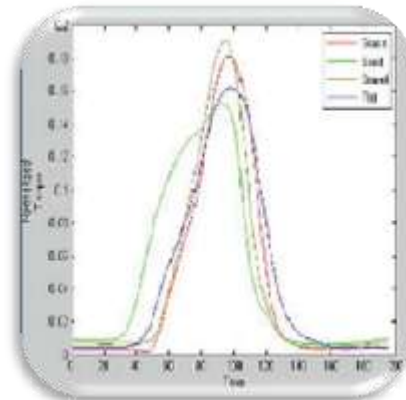


Abbildung 2.3: gelernte Kraftaufnahme-Kennlinien für die Böden Gras, Sand, Schotter, Eben. [Kim10]

Die Beinkontroller des Roboters AMEE liefern darüber hinaus noch Informationen über eine eventuelle Kollision oder Abweichung zur beauftragten Fußposition [Ruh11]. Gegebenenfalls wären Beschleunigungsdaten eines Gyroskops ebenfalls eine Bereicherung für die propriozeptive Analyse.

3 Ausblick

3.1 Lösungsansatz




Abbildung 3.1: Modell des Reinforcement Learnings

Ziel dieser Arbeit ist es, ein fortwährend lernendes Modul zu entwickeln, welches die unmittelbare Umgebung wahrnimmt und eine Auswahl guter Trittpositionen unter Aspekten der Robustheit, Erreichbarkeit, Kollisionsfreiheit und des Bewegungsfortschritts vornimmt, wobei das Reinforcement Learning, welches ein Lernen auf Basis von Erfahrungen modelliert, als lernalgorithmisches Gerüst dient. Anhand der visuellen Wahrnehmung der Umgebung (Exterozeption) wird der Untergrund

bezüglich seiner Tritteigenschaft eingeschätzt, woraufhin in der Regel die vorteilhafteste Position selektiert wird. Während des Ausführens des Schritts geben dann propriozeptive Daten der Beinsensorik eine Rückmeldung über die tatsächlichen Laufeigenschaften und werden zur Verbesserung künftiger Schätzungen herangezogen.

Im Zuge der Bachelorthesis von Jan Ruhnke [Ruh11] wurde eines der vier Beine konstruiert und eine Steuerung dafür entwickelt. Im Rahmen des Projekts AMEE wird der Prototyp vervollständigt und das softwaretechnische Laufsystem entwickelt [Ruh12], welches letztlich mit der „Foothold Selection“ gekoppelt wird.

Im weiteren Verlauf dieser Arbeit muss ein Framework für das Reinforcement Learning entwickelt werden, das ein geeignetes Modell des Roboters (dem Agenten) und seiner Umwelt sowie eine Simulationsumgebung zur Evaluierung des Lernverhaltens beinhaltet. Es wird untersucht, welche Verfahren, Metriken und Analysen für die Merkmalsvektoren des Lernalgorithmus zielführend sind. Dabei können die Methoden zur optischen Analyse für die a priori Schätzung und denen der Propriozeption für die Rückmeldung und Verbesserung der Schätzungen im ersten Schritt unabhängig voneinander untersucht werden. Dafür ist es notwendig, neben dem physischen Robotermodell Simulationen mit beispielsweise Matlab/Simulink zu erstellen, in denen die jeweils andere Methode (Optik, Propriozeption) vereinfacht dargestellt werden können.

3.2 Risiken und Chancen

Da es sich bei dem Projekt AMEE um ein Engagement von Studenten der Hochschule für Angewandte Wissenschaften Hamburg handelt, steht die Realisierung eines Prototypen unter finanziellen Schwierigkeiten. Des Weiteren müssen die einzelnen Projektziele dem zeitlichen Rahmen des Studiums angemessen sein. Es besteht die Gefahr, dass viel Arbeit in wenig forschungsrelevante Themen wie die Erstellung von Simulationsumgebungen oder die Kalibrierung der Hardware gesteckt werden muss. Der hier untersuchte Ansatz zur selbstlernenden Auswahl von Trittpositionen basiert auf der Analyse geeigneter Sensordaten. Zum Einen gilt es herauszufinden, welche Merkmale zu einem möglichst generellen Lernerfolg führen können, um dem Anspruch vielfältiger, unbekannter und rauer Bodenbeschaffenheiten gerecht zu werden. Des Weiteren könnten die Forschungsergebnisse dazu führen, dass der Lernalgorithmus zu ineffizient und zu teuer ist oder das gesamte Verfahren zu geringe Generalisierungseigenschaften besitzt und nur eine weitere spezialisierte Insellösung darstellt.

Hausintern gibt es jedoch einige themenverwandte Projekte wie das Robocup Rescue-Projekt, einen Rescuesimulator zur Untersuchung von Evakuierungsszenarien oder den Forschungen zu

Haushaltsrobotern, mit denen Erfahrungen ausgetauscht werden können. Die Forschungen im DARPA Projekt „Learning Locomotion“ und deren Veröffentlichungen sind derzeit federführend innerhalb der hier behandelten Thematik und dienen als Referenz sowie Ideengeber. Viele dort festgestellten Probleme und Irrwege können so vermieden werden.

4 Zusammenfassung

Das angestrebte Ziel der eigenen Forschung ist es, eine a priori Bodenanalyse unter Aspekten der Standfestigkeit und Laufeigenschaften vorzunehmen, um sichere Auftrittpositionen für die Beine zu finden. Dies soll für möglichst vielfältige und im Idealfall auch für unbekannte Terrainarten möglich sein. Die Beurteilung soll das Pilotsystem dahingehend unterstützen, dass die einzelnen Schrittpunkte oder der Laufstil den Gegebenheiten angepasst werden können. Da im Rescue-Szenario mit unterschiedlichsten Bodentypen zu rechnen ist, sollte das System fortwährend aus den Erfahrungen dazulernen und somit die Bewertungsfähigkeit über die Zeit ausbauen und verbessern.

Für dieses Konzept bietet sich das Reinforcement Learning (RL) an, dessen Potential auch in der Robotik in diversen Arbeiten bereits gezeigt wurde. Eine Schätzung oder Beurteilung der vor dem Roboter liegenden Bodens, könnte wie bei dem Projekt von Liang Lu et. al. mittels einer Kombination aus Laserscan und IR-Kamera geschehen. Während sie mittels eines PNN wieder den Bodentyp klassifizieren, sollte im AMEE-System die Mobilitätseigenschaft klassifiziert werden (Zustand s) und als Eingang einer Schätzfunktion $V(s)$ dienen. Die gemachten Erfahrungen verbessern im RL die Schätzfunktion, sodass die Beurteilungsfähigkeit zunimmt.

Literaturverzeichnis

- [Bru08] **Bruno Siciliano, Oussama Khatib (Eds.). 2008.** *Handbook of Robotics*. 80125 Napoli, Italy & CA 94305-9010, USA : Springer Science+Business Media, 2008. e-ISBN: 978-3-540-30301-5.
- [Byl08] **Byl, Katie. 2008.** *Metastable Legged-Robot Locomotion, Thesis (Ph. D.)*. Cambridge, MA : MIT, 2008.
- [Est05] **Estremera, Joaquin und Gonzalez de Santos, Pablo. 2005.** *Generating continuous free crab gaits for quadruped robots on irregular terrain*. s.l. : IEEE Transactions on Robotics, 2005. 21(6):1067 – 1076.
- [Gon02] **Gonzalez, R. und Woods, R. E. 2002.** *Digital Image Processing*. Prentice Hall : s.n., 2002.
- [Har92] **Haralick, R. und Shapiro, G. 1992.** *Computer and Robot Vision*. s.l. : Addison-Wesley, 1992.
- [Her08] **Hertzberg, Joachim und Chatila, Raja. 2008.** *AI Reasoning Methods for Robotics. Handbook of Robotics*. Berlin : Springer, 2008.
- [Hil06] **Hilljegerdes, Jens, Spenneberg, Dirk und Kirchner, Frank. 2006.** *The Construction of the Four Legged Prototype Robot ARAMIES*. [Buchverf.] M. O. Tokhi, G. S. Virk und M. A. Hossain. *Climbing and Walking Robots*. Berlin Heidelberg : Springer, 2006.
- [Hof00] **Hoffman, Antony. 2000.** *Red Planet*. Warner Bros. Pictures, 2000.
- [Hon07] **Honda Motor Co., Ltd. September 2007.** *ASIMO Technical Information*. [PDF] s.l. : Honda Motor Co., Ltd., September 2007. kA.
- [Kal11] **Kalakrishnan, M., et al. 2011.** *learning, planning and control for quadruped locomotion over challenging terrain*. *International Journal of Robotics Research*. 2011, 30.
- [Kim10] **Kim, Kisung, et al. 2010.** *Performance Comparison between Neural Network and SVM for Terrain Classification of Legged Robot*. *SICE Annual Conference*. 2010.
- [LuL09] **Lu, Liang, et al. 2009.** *Terrain Surface Classification for Autonomous Ground Vehicles Using a 2D Laser Stripe-Based Structured Light Sensor*. *IEEE/RSJ IROS*. 2009.
- [Rai08] **Raibert, Marc, et al. 2008.** *BigDog, the Rough-Terrain Quadruped Robot*. Waltham, MA : Boston Dynamics, 2008.

[Reb08] **Rebula, John R., et al. 2008.** *A Controller for the LittleDog Quadruped Walking on Rough Terrain.* [PDF] Florida 32502, USA : Florida Institute for Human and Machine Cognition, 2008. jrebula@alum.mit.edu.

[Ruh12] **Ruhnke, Jan. 2012.** *A Walksystem for a Quadruped Rough Terrain Robot, Controller Concepts (Studienarbeit).* Hamburg : Hochschule für Angewandte Wissenschaften, 2012.

[Ruh11] —. **2011.** *Entwicklung und Realisierung eines vierbeinigen USAR-Roboter-Laufsystems, Thesis (BA).* Hamburg : HAW Hamburg, 2011.

[Sut98] **Sutton, Richard S. und Barto, Andrew G. 1998.** *Reinforcement Learning: An Introduction.* Cambridge : MIT Press, 1998. ISBN 978-0262193981.

Anhang A

A.1 Zero Moment Point

Das Druckzentrum (Center of Pressure, COP) ist der auf die Oberfläche projizierte Zero Moment Point (ZMP), bei dem die Summe aller Drehmomente gleich Null ist. Ergänzend zum Massezentrum (Center of mass, COM) berücksichtigt der ZMP auch Beschleunigungen. Ein stehendes oder sich nur langsam Bewegendes Objekt ist dann stabil, wenn sich der COM innerhalb des Stützpolygons befindet (Fläche innerhalb der Stützpunkte). Bei sich dynamischer bewegenden Objekten muss hingegen der ZMP berücksichtigt werden, sodass sich hier der COP innerhalb des Stützpolygons befindet.




Abbildung A.4.1: Darstellung von COP und COM

Das Druckzentrum (Center of Pressure COP, auch ZMP) ist in diesem Beispiel nicht mit dem Massezentrum (COM) zusammengefasst. Vorausgesetzt, die Höhe und Winkeldrehungen des Körpers bleiben konstant, gibt es eine momentane auf den Körper wirkende Beschleunigung in die Richtung, vom COP zum COM in der XY-Ebene. [Byl08]