



Hochschule für Angewandte Wissenschaften Hamburg
Hamburg University of Applied Sciences

Ausarbeitung

Björn Bettzüge

Sicheres Navigieren in unwegsamem Gelände

Inhaltsverzeichnis

1	Einführung	4
2	Verwandte Arbeiten	5
2.1	Maschinelles Lernen	5
2.1.1	Bewertung	7
2.2	Performance Comparison between Neural Network and SVM for Terrain Classification of Legged Robot [Kim10]	7
2.2.1	Zusammenfassung	7
2.2.2	Bewertung	8
2.3	Terrain Surface Classification for Autonomous Ground Vehicles Using a 2D Laser Stripe-Based Structured Light Sensor [LuL09]	8
2.3.1	Zusammenfassung	9
2.3.2	Bewertung	9
2.4	Efficient vision-based navigation [Hor10]	10
2.4.1	Zusammenfassung	10
2.4.2	Bewertung	11
2.5	Reinforcement Learning an Robotern mit neuronalen Netzen [Tok08]	11
2.5.1	Zusammenfassung	11
2.5.2	Bewertung	11
2.6	Mobility characterization for autonomous mobile robots using machine learning [Tra11]	12
2.6.1	Zusammenfassung	12
2.6.2	Bewertung	13
2.7	Cost-efficient global robot navigation in rugged off-road terrain [Bra11]	13
2.7.1	Zusammenfassung	13
2.7.2	Bewertung	14
3	Resümee	15
	Literaturverzeichnis	16

1 Einführung

Das Projekt AMEE 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. Die aktuellen Forschungen des Autors befassen sich mit der Frage, wie sicher im Sinne der Standfestigkeit die Bodenbeschaffenheit für einen laufenden Roboter ist. 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.



Abbildung 1: Vision AMEE in Ruine

Oberflächenklassifizierung ist für laufende Roboter ein wichtiges Thema, das die Effizienz des Roboters maßgeblich beeinflussen kann. Dies gilt insbesondere im freien Feld oder beschädigten Gebäuden, wo die Oberfläche oftmals äußerst vielfältig ist. Auf flachem Grund können sich Roboter schnell und reibungslos bewegen, schwieriger und gefährlicher wird dies bei Flüssigkeiten (Wasser, Schlamm, Öl, etc.) oder unwegsamem Gelände. Mittels Regelungstechnik kann ein laufender Roboter zwar mehr oder weniger im Gleichgewicht gehalten werden. Vorteilhafter wäre es aber sicherlich, das Laufverhalten von vornherein den Bodenbeschaffenheiten anzupassen. Daher müssen Roboter ihr Terrain kennen, welches sie beschreiten.

Jan Ruhnke entwickelte und entwarf für das Projekt AMEE die Beine samt einem MCU-gestützten Laufsystem, das unter anderem die inverse Kinematik und eine rudimentäre Kollisionskontrolle umsetzt [Jan11]. Es ist mit Kontakt- Winkel- und Drehmomentsensoren ausgestattet. Jedes Bein besitzt dabei eine eigene Steuereinheit, die soweit abstrahiert ist, dass sie z.B. einen Befehl „Setze Fuß an Stelle (x,y,z)“ realisiert. Des Weiteren steht ein Konzept für eine hierarchisch übergeordnete Steuereinheit zur Koordination der Beine und Umsetzung von Laufstilen. Es gilt dabei zu erwähnen, dass AMEE als statischer und nicht als dynamischer Läufer konzipiert ist. Dies ist bildlich formuliert in etwa der Vergleich einer Echse mit einem Esel (oder dem „BigDog“ von Boston Dynamics). Dadurch konnte, auch aus Gründen der Performance, auf eine Regelung der Beine verzichtet werden, sie werden stattdessen lediglich gesteuert. Umso wichtiger ist dann aber eine vorausrechnende Beurteilung der Bodenbeschaffenheiten, um den sicheren Gang des Roboters zu gewährleisten.

2 Verwandte Arbeiten

Im Folgenden wird eine Auswahl von Konzepten und Arbeiten vorgestellt, an die sich diese Arbeit orientiert, und sie maßgeblich vorantreiben sollen.

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-Entscheidungsprozessen (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-Netze¹. 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.

¹ J. Pearl: Probabilistic Reasoning in Intelligent Systems (Morgan Kaufmann, San Mateo 1988)

2.1.1 Bewertung

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 Performance Comparison between Neural Network and SVM for Terrain Classification of Legged Robot [Kim10]

Kisung Kim, Kwangjin Ko, Wansoo Kim, Seungnam Yu, Changsoo Han
Mechanical Engineering, Hanyang Univ. Seoul, Korea

2.2.1 Zusammenfassung

In diesem Forschungsprojekt beschäftigte man sich mit der Frage, wie die Bodenbeschaffenheit anhand von propriozeptiven Daten (Selbstwahrnehmung von Position und Lage im Raum) eines Roboterbeins ermittelt werden kann. Das Testsystem ist ausgestattet mit einem Kraftaufnahmesensor und Drehmomentsensoren an den drei Antrieben.

Die Aufgabe besteht darin anhand der Messdaten während der Bewegung vier unterschiedliche Bodentypen zu klassifizieren: Sand, Schotter, Gras, ebener Fußboden. Die drei erstgenannten gehören dabei in die Kategorie der rauen Geländearten, bei denen letztlich eine vorsichtigere Gangart gewählt werden soll.




Abbildung 2: Roboterbein

Als erster Schritt ist eine Merkmalsextraktion durchzuführen. Das Seouler Forschungsteam verwendete bei den in Vektorform vorliegenden Daten des Kraftaufnehmers die Hauptkomponentenanalyse (engl. kurz: PCA). Ein Durchschnittswert für jede Bodenart diente dabei als Standardvektor auf die die Eingangssignale schließlich projiziert und dem

Lernverfahren übergeben wurde. Ein anderes untersuchtes Verfahren analysiert die statistische Verteilung der Daten, insbesondere die Varianz, Kurtosis (Wölbung des Graphen), und Verzerrung (skewness). Die Kraftverteilung variiert je nach Gelände charakteristisch und kann im Vergleich mit der aktuellen Bodenreaktionskraft zur Identifizierung des Geländes und als Eingang für die Lernalgorithmen benutzt werden.

Im nächsten Schritt werden die beiden Klassifizierungs- und Lernmethoden Stützvektormaschine (SVM) und Neuronale Netze mit Back Propagation (BPNN) mit einander verglichen. Da die SVM eigentlich ein binärer Klassifikator ist, erfolgte hier die Analyse in mehreren Schritten: „Schotter? Wenn nein, Gras?“, usw. Dies reduzierte die Erkennungsrate im Test auf lediglich 50%. Bei dem verwendeten BPNN mit zwei Hidden-Layern á 20 Perceptrons lag die Erkennungsrate dagegen bei 70% bis 80% bei einer allerdings schwankenden Rate nach jedem erneuten Lernzyklus. Generell wirkte sich die statistische Merkmalsextraktion gegenüber PCA positiver in den Tests aus.

2.2.2 Bewertung

Das Ergebnis der Seouler zeigt, dass für eine zuverlässige Bodenanalyse lediglich anhand propriozeptiver Daten zusätzliche Sensoren wie z.B. Drehmoment, Neigung und Beschleunigung sinnvoll wären. Nichts desto trotz zeigt dieses Beispiel potentiell gute Resultate und verspricht eine ressourcenschonende Möglichkeit der Klassifizierung mittels NN in Verbindung mit einer statistischen Analyse. Es kommt dem im Projekt AMEE angestrebten bionischen Ansatz insofern nahe, dass auf das „Schrittgefühl“ reagiert wird, um die Laufsicherheit zu erhöhen. Es ist zwar keine Vorabanalyse, wie angestrebt, kann aber gegebenenfalls in Verbindung mit anderen Lernverfahren auch zur Verbesserung der Beurteilungsfähigkeit herangezogen werden. Anstatt des Bodentyps könnte dann auch die Laufeigenschaft klassifiziert und als Feedback an ein RL-Verfahren gegeben werden.

2.3 Terrain Surface Classification for Autonomous Ground Vehicles Using a 2D Laser Stripe-Based Structured Light Sensor [LuL09]

Liang Lu, Camilo Ordonez, Emmanuel G. Collins, Jr. and Edmond M. DuPont,
College of Engineering, Florida, USA

2.3.1 Zusammenfassung

Auch diese Gruppe aus Florida strebt eine Terrainklassifizierung an, um allgemein Bodenvehikeln eine Anpassung der Bewegungsart zu ermöglichen und analysiert hierzu mit visuellen Verfahren den direkt vor dem Fahrzeug liegenden Boden. Es geht über die Frage hinaus, ob der Weg passierbar ist, sondern soll auch die Frage nach „wie gut“ beantworten. Da bildgebende Verfahren stark von den Lichtverhältnissen abhängen, insbesondere was Farben und Kontrast angeht, setzten die Forscher auf einen Laser-Stripe-Sensor in Verbindung mit einer Infrarot-Kamera, sodass das System auch bei Dunkelheit arbeiten kann. Das Verfahren untersucht dazu die Ortsfrequenz, also den Kehrwert des kleinsten räumlichen Abstands sich wiederholender Muster, und die Textur. Der Bodentyp kann anhand dieser Merkmale und mit einem probabilistischen Neuronalen Netz (PNN) klassifiziert werden, im Test waren das Asphalt, Gras, Kies und Sand.




Abbildung 3: Bodenklassifizierung mittels Laserscan und IR-Kamera.

Das PNN basiert auf Bayes-Klassifikatoren und lernt im überwachten Training die Verteilungsfunktionen, die die Wahrscheinlichkeit einer gelernten Kategorie in Bezug auf den Eingangsvektor schätzt: $P(C_i | \vec{x})$. Da gemäß der Bayes-Regel die relative Kategoriehäufigkeit $P(C_i)$ bekannt sein muss, wurde hier eine Gleichwahrscheinlichkeit angenommen. Um die Textur zu beschreiben wurde eine Gray-Level Co-Occurance Matrix (GLCM) [Verweis 23] verwendet. Die Ortsfrequenz wird rechnerisch noch um die Nullfrequenz (DC) und einer durchschnittlichen Steigung bereinigt. Aus den gewonnenen Daten lassen sich Kontrast, Pixelkorrelation, Energie und Homogenität berechnen die über mehrere Samples als Merkmalsvektor in das PNN gehen.

2.3.2 Bewertung

Die Laserscanvariante trifft ziemlich genau das Ziel der Präanalyse. Es besteht auch dadurch, dass sowohl Breiten- als auch Tiefeninformationen vorhanden sind und gegebenenfalls auch für andere Analysen genutzt werden können (Hindernisse, Abgründe, etc.). Die Testresultate mit einer Erkennungsrate von 86% bis 100% sind zufriedenstellend und mit geschätzten Kosten von 100\$ ist das System relativ günstig. Allerdings wird auch

hier ausschließlich auf überwachtes Lernen einer Auswahl von Bodentypen gesetzt. Für das AMEE-System ist aber ein fortwährendes Lernen angedacht, sodass auch hier eher eine Klassifikation nach Laufeigenschaft vorteilhafter wäre. So könnte im RL-Kontext das Lasersystem durch die Voranalyse die Aktionsstrategie liefern, also eine Einschätzung, wie Vorteilhaft ein bestimmter Bodenabschnitt wäre. Im Zusammenhang mit dem Feedback durch propriozeptive Daten, könnte dann die Schätzung verbessert werden.

2.4 Efficient vision-based navigation [Hor10]

Armin Hornung, Maren Bennewitz, Hauke Strasdat
Arbeitsgruppe Humanoide Roboter an der Universität Freiburg.

2.4.1 Zusammenfassung

Typischerweise wird Reinforcement Learning in der Robotik für eine Armwinkelsteuerung zwecks Bewegung [Tok08] oder für Navigation verwendet. So auch in der Arbeit aus der Universität Freiburg, wo es um effiziente Navigation und Pfadverfolgung geht. Letztere wird durch Odometrie und durch visuelle Merkmale (SURF) unterstützt die bei zunehmender Geschwindigkeit allerdings an Schärfe verlieren, wodurch die Unsicherheit bei der Lokalisierung steigt und das Fahrzeug zwischendurch halten muss, um sich neu zu orientieren. Die Arbeitsgruppe konnte mittels RL dem System erfolgreich beibringen, die optimale Geschwindigkeit zu wählen, sodass eine zuverlässige Lokalisierung möglich ist und das Ziel schnellstmöglich erreicht wird.

Sie benutzten SARSA- λ und einen Zustandsraum, der sich aus Euklid'scher Distanz sowie relativen Winkel zum nächsten Zielpunkt und einer Lokalisierungsunsicherheit, die sich aus einem Kalman-Filter angewandt auf SURF-Merkmale und Odometrie ergibt, zusammensetzt. Die Wahl der Geschwindigkeit ist die Aktion und als Belohnung bzw. Bestrafung wurde +100 bei Erreichen eines Zwischenziels beziehungsweise ein $-\Delta t$ sonst gesetzt.

Die Stärke des RL-Verfahren zeigte der Vergleich mit einer in der Robotik verbreiteten Dual-Mode-Control, bei der in diesem Fall feste Grenzen für die Unsicherheit festgelegt sind, die die Wahl vorprogrammierte Geschwindigkeiten regelt. Mit RL fuhr das Fahrzeug im Mittel schneller und genauer. Die gelernte Strategie wurde letztlich noch durch Clustering ressourcenschonend komprimiert.

2.4.2 Bewertung

Auch wenn die Freiburger Arbeit oder die folgende von M. Tokic nichts mit einer Klassifizierung von Bodenlaufeigenschaften zu tun hat, demonstrieren sie doch beispielhaft das Potential von RL und die Methodik, um ein derartiges Lernverfahren zu modellieren.

2.5 Reinforcement Learning an Robotern mit neuronalen Netzen [Tok08]

Michel Tokic, Hochschule Ravensburg-Weingarten

2.5.1 Zusammenfassung

In der Master-Thesis wird am Beispiel eines einarmigen Krabbelroboters, der mit RL die Fortbewegung gelernt hat, demonstriert, wie das Problem der mit der Größe des Eingangsvektors exponentiell wachsenden Zustandsraum mit Neuronalen Netzen, die die Schatzfunktion V (bzw. Q) lernen, optimiert werden kann.

2.5.2 Bewertung

Da RL ein zu untersuchendes Verfahren im AMEE-System ist, zeigt diese Arbeit, wie auch die vorangegangene, praktische Umsetzungen der Optimierung, insbesondere im Hinblick auf Speicherlast.

2.6 Mobility characterization for autonomous mobile robots using machine learning [Tra11]

Eric Trautmann, Laura Ray - Dartmouth College Hanover, USA

2.6.1 Zusammenfassung

Im Rahmen eines DARPA-Forschungsprojekts wurde die Verbesserung der autonomen Mobilität eines Lastfahrzeugs für den Einsatz in der Arktis entwickelt. Die besondere Herausforderung liegt bei der kontrastarmen aber in ihren Fahreigenschaften doch vielfältigen Schneelandschaft. Der Ansatz ist eine Präimmobilitätserkennung anhand propriozeptiver Daten. Mit einer SVM wird daraus die Merkmalsextraktion vorgenommen und eine Präimmobilitätssituation erkannt. Daraufhin wird das Terrain mittels eines Hidden-Markov-Modells (HMM) klassifiziert, um adäquat darauf zu reagieren und ein Festfahren oder Umstürzen rechtzeitig zu verhindern.

Die SVM erhält die Sensordaten zu Motorstrom, Radschlupf, optisch erfasster Geschwindigkeit und, davon hergeleitet, die Beschleunigung. Mit handbeschrifteten Trainingsdaten wurden drei SVMs trainiert, die die Zustände mobil, fast immobil und immobil klassifizieren. Das Terrain ebenfalls mit SVMs zu klassifizieren, hat das Team wegen schlechter Generalisierungseigenschaften verworfen. Darüber hinaus verwirft der SVM-Ansatz zeitliche Information durch die Annahme, dass aufeinanderfolgende Datenpunkte unabhängig und identisch verteilt sind. Stattdessen wurde ein HMM erstellt, ein stochastisches Modell das mittels einer Wahrscheinlichkeitsverteilung über die beobachteten Daten und Zustandsübergangswahrscheinlichkeiten Rückschlüsse auf den inneren, versteckten Zustand, in diesem Fall den Terraintyp, erlaubt. Trainingsdaten wurden mit einem Gauß-Mischungs-Modell modelliert. Für jeden Hindernistyp c wurden HMMs ausgebildet, das heißt, unter einer Reihe von Beobachtung O werden die Modellparameter $\{\pi, A, \phi\}$ optimiert, um die bedingte Wahrscheinlichkeit $p(O | \lambda_c)$ zu maximieren. Das Training erfolgt mit dem Baum-Welch-Algorithmus [Dug96].

2.6.2 Bewertung

Wie auch in dem Seouler Projekt wurden propriozeptive Daten mit einer SVM und stochastischen Verfahren zur Bodenanalyse genutzt. Das HMM zeigt dabei einen alternativen Ansatz zu Neuronalen Netzen. Beide Projekte ermitteln somit die Fahreigenschaft und klassifizieren darüber hinaus die Ursache, was zusammen wertvolle Informationen zur Verbesserung eines Schätzverfahrens sind. Allerdings gilt aus Sicht des AMEE-Projekts auch hier die Beschränkung auf bestimmte Geländearten Nachteilig. Es besteht jedoch die Aussicht Mobilitätseigenschaften und Geländecharakteristiken im RL-Model zu vereinen.

2.7 Cost-efficient global robot navigation in rugged off-road terrain [Bra11]

Tim Braun, Forschungsgruppe Robotersysteme, TU Kaiserslautern

2.7.1 Zusammenfassung

Tim Braun beschäftigt sich mit einer kosteneffizienten Navigation durch raues Gelände. Es wird ein auch für große Umgebungen gut skalierbares System vorgestellt, das topologische Karten (gute Skalierbarkeit) mit metrischen Informationen (ermöglicht Kostenbewusstsein) anreichert. Durch Kosten und Risikoermittlung kann die Route online optimiert werden. Die Schwierigkeit bei der Planung und einer verhaltensbasierten Steuerung besteht darin, dass die tatsächlichen Kosten einer Kante i.d.R. erst während der Bewegung bekannt werden.

Das Verhaltensmodell ist in einer Subsumption-Architektur umgesetzt, wo die Navigatorkomponente die Karte hält und die Richtung vorgibt. Die Pilotkomponente beinhaltet einen Satz exterozeptiver Verhalten A_i zur Hindernis Ausweichung und einen Satz propriozeptiver Verhalten B_i für die Motoransteuerung. Die auf $[0, 1]$ normierten Werte r^{A_i} und r^{B_i} geben zu einer Sample-Zeit t an, in welchem Maße das jeweilige Verhalten




Abbildung 4: online Kosten/Risiko-Gewichtung

ausgeprägt ist. p^{Ai} teilt zudem die Position eines Hindernisses mit. Die Motorsteuerung, die mit dem Energieverbrauch verbunden ist, kann dann als Maß für die Kosten genommen werden: $W = \int_t \sum r^{Bi}(t) dt$. Das Hindernissverhalten dient in Verbindung mit einer Spatial Map S dann der Risikoermittlung: $R = \sum S$ mit $S(p^{Ai}(t)) = \max(S(p^{Ai}), r^{Ai})$. W und R dienen dann als neue Kantengewichtung für die topologische Karte des Navigators.

2.7.2 Bewertung

Obwohl das Hauptaugenmerk hier auf eine kosten- und risikosensitive Navigation mittels einer gut skalierbaren Karte liegt, lernt man doch daraus, wie ein beschrittener Weg nachträglich bewertet werden kann. Das Verfahren nutzt die in den meisten Robotern vorhandene Hinderniserkennung sowie vorliegende propriozeptive Daten aus. Es hat insofern Ähnlichkeit und Nutzen für das AMEE-Schätzverfahren mit RL, dass eine vorhandene Bewertung (V-Funktion) nachträglich mit aktuellen Daten (Reward) verbessert wird. Das Verfahren hat allerdings den Nachteil, dass es eine (vorhandene) Karte zu einem speziellen Gebiet verbessert wird und das effektiv erst durch mehrmaliges Befahren der Kanten, was im Widerspruch zu einer möglichst allgemeinen, wiederverwendbaren Analyse und dem Einsatzszenario von AMEE steht.

3 Resümee

Das angestrebte Ziel der eigenen Forschung ist es, eine a priori Bodenanalyse unter Aspekten der Standfestigkeit und Laufeigenschaften vorzunehmen. 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 an, dessen Potential auch in der Robotik unter anderem durch die Arbeiten von A. Hornung et. al. und M. Tokic gezeigt wurde, die sich allerdings eher mit der Bewegungsoptimierung beschäftigen.

Ebenfalls mit Roboterbeinen und dem Laufen haben sich Kisung Kim et. al. auseinandergesetzt, die mittels rein propriozeptiver Daten den Bodentyp klassifizieren. Eine ähnliche Aufgabe, aber für ein Schneefahrzeug und mit anderen stochastischen Verfahren, haben E. Trautmann et. al. bewältigt. Die Lösungen bieten zwar keine a priori Bodenanalyse, zeigen aber im RL-Kontext Wege, deren Auswertungsverfahren als Feedback bzw. Reward zu nutzen, die aktuell gemachte Erfahrung.

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. Ein konzeptionell der Arbeit von Tim Braun ähnlicher Gedanke, der eine online Kosten- und Risikoanalyse vornimmt, um die Kantengewichtung einer topologischen Karte anzupassen und so über die Zeit sicheres Navigieren ermöglicht. Seine Arbeit ist abgesehen von der abstrakten Ähnlichkeit interessant, dass sie die Idee aufwirft, die gewonnenen Erfahrungen auch in der Kartierung und Routenplanung zu nutzen.

Literaturverzeichnis

[Bra11] **Braun, T. 2011.** Cost-efficient global robot navigation in rugged off-road terrain. *Künstliche Intelligenz*. 2011, 25, pp. 173-177.

[Dug96] **Dugad, R. and Desai, U. 1996.** *A tutorial on hidden Markov models*. Bombay : Indian Institute of Technology, 1996.

[Her08] **Hertzberg, Joachim and Chatila, Raja. 2008.** AI Reasoning Methods for Robotics. *Handbook of Robotics*. Berlin : Springer, 2008.

[Hor10] **Hornung, Armin, Bennewitz, Maren and Strasdat, Hauke. 2010.** Efficient vision-based navigation. *Autonomous Robots*. April 2010, 29, pp. 137-149.

Performance Comparison between Neural Network and SVM for Terrain Classification of Legged Robot. [Kim10] **Kim, Kisung, et al. 2010.** Taipei : SICE Annual Conference, 2010.

[Jan11] **Ruhnke, Jan. 2011.** *Entwicklung und Realisierung eines vierbeinigen USAR-Roboter-Laufsystems*. Hamburg : HAW Hamburg, 2011.

Terrain Surface Classification for Autonomous Ground Vehicles Using a 2D Laser Stripe-Based Structured Light Sensor. [LuL09] **Lu, Liang, et al. 2009.** St. Louis : IEEE/RSJ Intern. Conf. on Intelligent Robots and Systems, 2009.

[Tok08] **Tokic, Michel. 2008.** Reinforcement Learning an Robotern mit neuronalen Netzen. *Masterthesis*. Weingarten : Hochschule Ravensburg-Weingarten, 2008.

[Tra11] **Trautmann, E., Ray, L. 2011.** Mobility characterization for autonomous mobile robots using machine learning. *Autonomous Robots*. 2011, 30, pp. 369-383.

