

Autonomieerhöhung durch Lernen

Teil II: Erlernen von Heuristiken, Planungs- und Kommunikationsgrundlagen

Autonomy Increase by Learning

Part II: Learning of Heuristics and Basics for Planning and Communication

Henning Tolle

Für die Kooperation von Mensch und Roboter – z.B. im normalen Haushalt – sind menschenähnliche Dienstleistungsroboter von Interesse. Für ihre Steuerung sind Autonomie und Selbstadaptation durch Lernen notwendig. Die Arbeit behandelt ausgehend von einer dafür geeigneten Architektur Lernvorgänge auf den oberen, für selbständiges Handeln zuständigen Ebenen. Grundsätzliches und Lernen auf den unteren, motorischen Ebenen wurden in einer vorausgegangenen Arbeit erörtert.

Robots similar to humans are of interest for the cooperation of humans and robots – e.g. in the normal home environment. The respective control task requires autonomy based – at least partly – on self adaptation by learning. Making use of an adequate control architecture this paper deals with learning on the upper, for autonomous acting responsible levels. An earlier article discusses learning principles and learning on the lower, motor control levels.

1 Einleitung

Nach meinen heutigen Vorstellungen stellt Bild 1 eine geeignete Informationsverarbeitungsarchitektur dar für einen Roboter als menschlichen Assistenten – z.B. eine menschenähnliche Haushaltshilfe. In Teil I von „Autonomieerhöhung durch Lernen“ – at 5/2001 – bin ich dabei auf Grundsätzliches und auf Lernen für den motorischen Bereich, die lernende Vorsteuerung und die Bewegungssequenzen eingegangen. Hier werde ich mich mit Lernen in den Bereichen Datenverdichtung, Kommunikation, Planung und Heuristiken auseinandersetzen.

Beim Lebewesen gibt es stets eine Mischung aus genetischen Vorgaben und Lernvorgängen, wobei nach [10] in der Evolution zu höheren Lebewesen schrittweise die genetischen Vorgaben zugunsten des Lernens verringert wurden. Die entsprechende Frage in technischen Systemen ist, was für algorithmische Strukturen sollte der Ingenieur vorgeben, um durch effektives Lernen die hohe Adaptionfähigkeit des Menschen an unterschiedlichste Umgebungen und Aufgaben zu erzielen, entsprechende Sensorik, Aktorik und mechanischen Aufbau vorausgesetzt. In den [15] zugrunde liegenden Arbeiten wurden Handlungsalternativen für die heuristische und Planungsebene noch als vom

Ingenieur in Form von Regeln fest vorgegeben angesehen, in den Untersuchungen seitdem sind diese Vorgaben zugunsten von Lernprozessen verringert worden. Diese sollen am Beispiel der mobilen Robotik hier diskutiert werden.

Das selbsttätige Zusammenfassen von Datensequenzen zur Charakterisierung der Ausgangslage für eine heuristische Entscheidung oder Planungsentscheidung ist ebenso wie die Kommunikation zwischen der so generierten Klassifikation der jeweiligen Situation mit den Vorstellungen eines Roboternutzers eng mit dem Erlernen des heuristischen Verhaltens bzw. dem Aufbau einer Planungsstruktur verbunden. Sie werden deshalb innerhalb der Erläuterung zu Heuristiken und Planung mit dargestellt, womit sich für den Aufsatz folgender Aufbau ergibt:

Abschnitt 2 behandelt das Lernen auf der heuristischen Ebene, Abschnitt 3 das Lernen für Planung und Kommunikation mit den Unterabschnitten Aufbau einer Planungsebene und Einbeziehung einer Kommunikationsebene.

Der Aufsatz ist m.E. trotz einiger Rückverweise auch ohne Kenntnis von Teil I lesbar.

Grundlage für die praktischen Untersuchungen, die für das Lernen eine Vorbedingung sind, war im Übrigen der in Bild 2 dargestellte Experimentierroboter, ALEF.

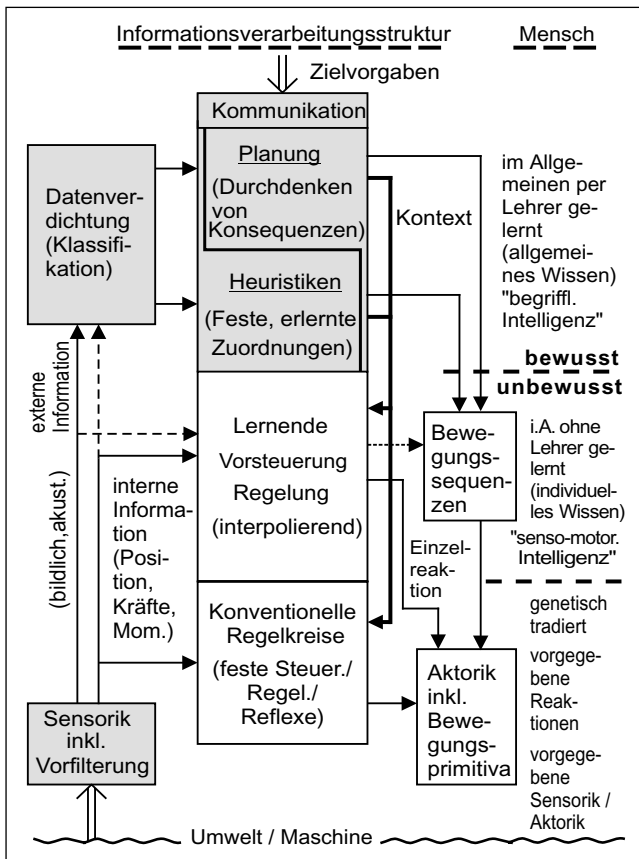


Bild 1: Architektur zur Imitation der menschlichen neuronalen Informationsverarbeitung – schraffiert sind die in diesem Aufsatz behandelten Elemente.




Bild 2: Der Experimentierroboter ALEF; die oberen Aufbauten mit Kamera wurden erst für [18] ergänzt; für [9] standen nur die Ultraschallsensoren und die interne Messung der Winkeländerungen an den Motorachsen (goniometrische Sensorik) zur Verfügung.

2 Lernen auf der heuristischen Ebene

Heuristiken zeichnen sich durch einfache, aber feste Verhaltensweisen aus, die allerdings unter Umständen auch völlig falsch sein können.

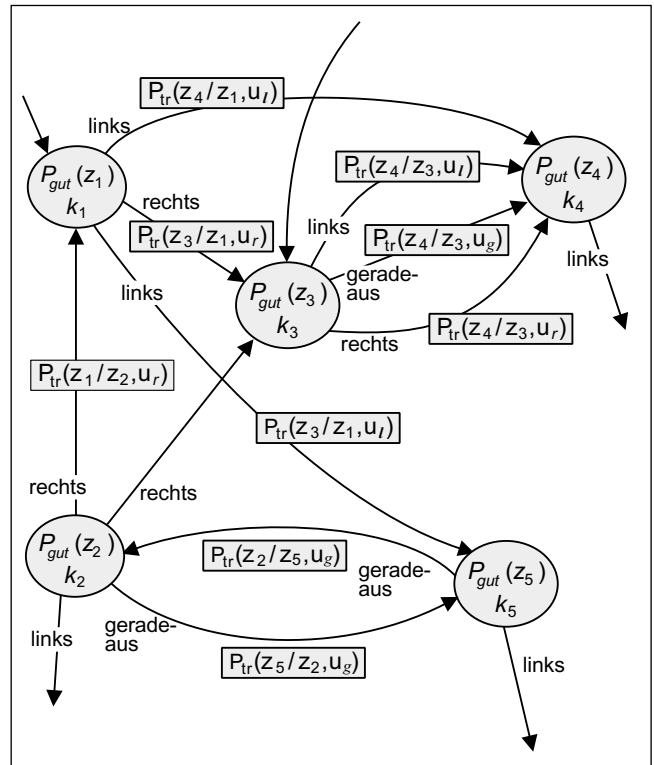


Bild 3: Zustandsgraph, der durch das Lernen der Kollisionsvermeidung als Verhalten entsteht nach [9]. Die P sind angenäherte Wahrscheinlichkeiten.

Das Erlernen von heuristischem Verhalten wurde in [9] an Hand des Problems der Kollisionsvermeidung untersucht. Es erfolgte eine einfache Einschränkung auf drei Fortschrittsrichtungen: Rechts, links, geradeaus (Strukturvorgabe). Die jeweils einzuschlagende Richtung wird mit Hilfe eines lernend aufgebauten Zustandsgraphen (Bild 3) festgelegt.

Die Zustände, die den Knoten des Graphen entsprechen, ergeben sich aus einer unüberwachten Klassifikation der jeweiligen Messwerte der nach vorne und zur Seite gerichteten Hälfte der Ultraschallsensoren (Bild 4a), womit ein 13dimensionaler Sensordatenraum entsteht. Ein Reflexsystem definiert zudem vorab aus den Sensordaten, ob das Fahrzeug in gefährlicher Nähe eines Hindernisses – schlecht – oder dies nicht ist – gut – (vgl. Bild 4b).

Für die unüberwachte Klassifikation wurde die Abwandlung eines RCE-Klassifikators (Restricted-Coulomb-Energy-Klassifikator, siehe z.B. [13]) verwendet. Er arbeitet mit Hyperkugeln um sogenannte R-Vektoren (vgl. Bild 5), und neue Gebiete werden unüberwacht lernend so eingerichtet:

- fällt ein zu klassifizierender Merkmalsvektor in keines der Einflussgebiete der bereits vorhandenen R-Vektoren, wird er selbst zu einem neuen R-Vektor.

Da für die Kollisionsvermeidung vor allem die Übergänge von guten zu schlechten Zuständen von Bedeutung sind und letztere vermieden werden, weshalb Bild 3 nur gute Zustände zeigt, wurde folgende Abwandlung vorgenommen: Die R-Vektoren sind Mittelwertvektoren von Sequenzen zeitlich aufeinanderfolgender Ultraschallvektoren. Eine Sequenz wird begonnen, wenn ein Sensordatenvektor

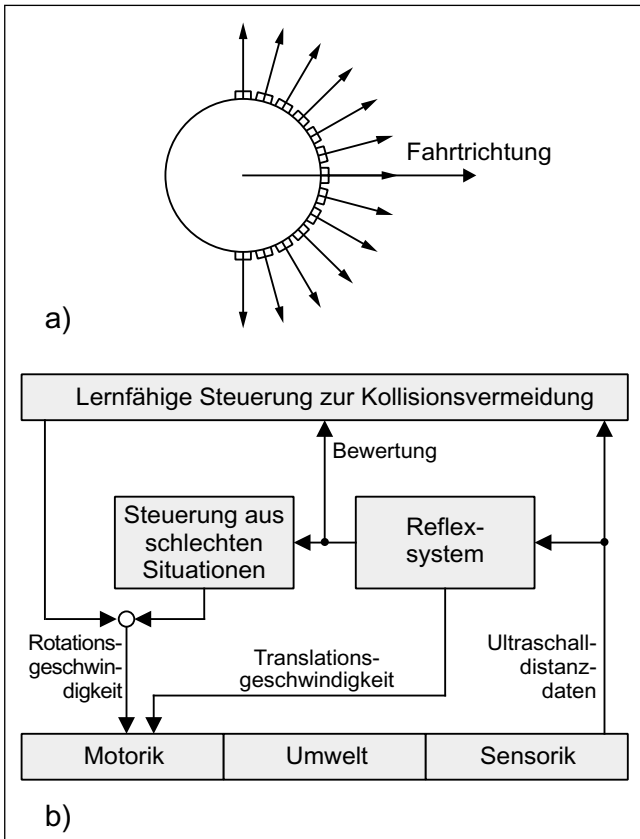


Bild 4: Ultraschallsensorkonfiguration (a) und Steuerungsregelungsstruktur (b) für die lernende Kollisionsvermeidung [9].




Bild 5: Prinzip der von Kurz bei der Kollisionsvermeidung benutzten RCE-Klassifikation (Restricted Coulomb Energy Klassifikation; R-Vektoren = Repräsentationsvektoren).

außerhalb aller bisher vorhandenen Einflussvektoren liegt und wird beendet, wenn

- dies entweder nicht mehr der Fall ist,
- oder sich die Bewertung durch das Reflexsystem ändert.

Dies hat zur Folge, dass die Grenze zwischen „gut“ und „schlecht“ recht genau durch Klassengrenzen angenähert wird. Für Einzelheiten und eine weitere Detaillierung des Algorithmus vgl. [9].

Hier erscheint mir interessant, dass diese ingenieurtechnisch motivierte Methodik in Übereinstimmung mit [14] mit Sequenzen als Grundelementen der Informationsverarbeitung auf einer „bewussten“ Ebene arbeitet und dazu in Übereinstimmung mit [2] von unüberwachtem Lernen ausgeht. Die Vorverarbeitung der Sensordaten durch Klassifikation als Eingangsvoraussetzung für die bewussten Ebenen gemäß Bild 1 ist hier zwar nicht neuronal orientiert,

ich werde aber im Zusammenhang mit der Planungsebene dazu noch auf einen entsprechenden günstigen Ansatz hinweisen.

Die Kanten des Zustandsübergangsgraphen aus Bild 3 entsprechen vollzogenen Übergängen und sind mit im Laufe der Zeit aufgebauten angenäherten Übergangsauftrittswahrscheinlichkeiten versehen, wobei der stochastische Charakter durch Ungenauigkeiten, Quantisierungen und Abstraktion der Sensordaten entsteht.

Eine geeignete Aktion wird gemäß Bild 6 dadurch gefunden, dass über mehrfache Prädiktion für einen vorgegebenen Horizont nach der höchsten Wahrscheinlichkeit gesucht wird, wieder einen guten Zustand zu erreichen. Der erste Übergang aus dieser Folge wird dann aufgeschaltet. In einer Umgebung in der keine Hindernisse vorhanden sind, wird der i.A. vorgegebenen Solltrajektorie gefolgt, die mit „Geradeaus“ identifiziert wird. Natürlich ist auch eine Neugierkomponente zum Lernen notwendig.

Bild 7 zeigt das Ergebnis des Lernens in einer einfachen Umgebung, Bild 8 eine Umgebung mit zwei Hindernissen, aus der gefolgert werden kann, dass ein Verhalten und nicht die Umgebung im Detail gelernt wurde: Ohne das Lernen in der Umgebung aus Bild 7 – die in der Realität Bild 8 mit nur einem Hindernis entspricht – dauert das Lernen in der

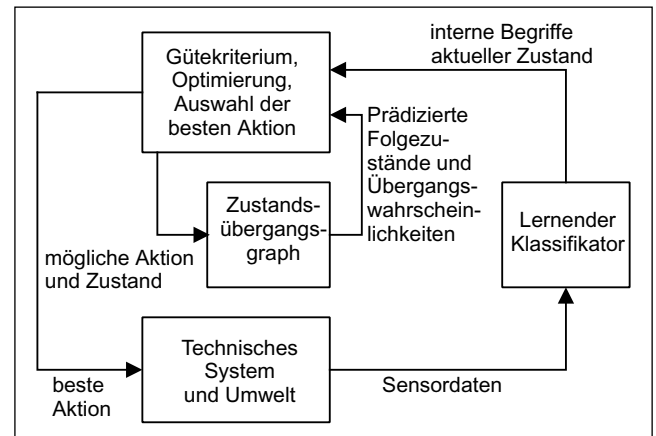


Bild 6: Architektur für das Erlernen des Zustandsgraphen zur Kollisionsvermeidung [9].




Bild 7: Ausschnitte einer realen Fahrt mit dem Experimentierfahrzeug „ALEF“ und der Struktur aus Bild 4b. Links: Anfangsphase der Umfahrung eines Hindernisses; rechts: Kollisionsvermeidung auf der Basis des Zustandsgraphen nach ausreichend langem Lernen [9].



Bild 8: Reale Experimentierumgebung mit zwei Hindernissen. Vorlernen mit einem Hindernis verkürzt das Lernen für die neue Aufgabe auf das Erlernen des Durchfahrens zwischen den Hindernissen [9].

Umgebung aus Bild 8 doppelt so lange wie unter Nutzung des Lernens in der einfachen Umgebung. Eine nähere Analyse zeigt, dass im Wesentlichen nur noch das Hindurchfahren zwischen zwei Hindernissen hinzugelehrt wird.

Interessant ist, dass [12] einen entsprechenden Ansatz erlernter Wahrscheinlichkeiten für ein an die zu bedienende Familie angepasstes Verhalten eines Serviceroboters benutzen: Die in [9] entwickelte Methodik ist damit möglicherweise ein prinzipielles Muster für das Erlernen von Heuristiken, die mehrere alternative Möglichkeiten und Schritte einbeziehen. Einfacheres, regelbasiertes Verhalten wird evtl. besser durch Fuzzy-Ansätze beschrieben, zumal diese wie in [5, Kapitel 12] beschrieben, ebenfalls aus Datenströmen durch Klassifikation gewonnen werden können.

Im Übrigen kann die Kollisionsvermeidung nach [9] auch mit einem lernenden Regelkreis wie LERNAS (vgl. [16]) bewältigt werden. Die zentralen Unterschiede sind:

- Der Zustandsübergangsgraph beschränkt sich auf einige wenige diskrete Richtungsentscheidungen, während LERNAS die einzuschlagende Richtung quasi kontinuierlich numerisch bestimmt.
- Während LERNAS interpoliert, klassifiziert der verhaltensorientierte Ansatz Situationen: Er nimmt selbständig eine Datenverdichtung vor, die bei LERNAS vom Systementwickler geeignet konzipiert und implementiert werden muss. Man zahlt für die selbständige Datenkompression allerdings mit einem erhöhten Lernaufwand.

3 Lernen für Planung und Kommunikation

Die grundsätzlichen Konzepte für den automatischen Aufbau einer das Durchprüfen alternativer Möglichkeiten erlaubenden Planungsebene wurden in [9] mit untersucht. Ich möchte aber die folgenden Ausführungen auf [18] stützen, weil dort im Hinblick auf die zusätzlich benutzte Bildverarbeitung die Sensorsignalklassifizierung komplexer zu

behandeln war und zudem die Anbindung an die menschliche Aufgabenvorgabe genauer untersucht wurde.

Grundsätzlich wird in [18] von dem Fernziel eines Haushaltsroboters ausgegangen. Es soll, wie bei einer menschlichen Haushaltshilfe, genügen, dem Roboter einmal die Wohnung zu zeigen, um dann Wünsche wie „decke den Teetisch im Wohnzimmer“ erfolgreich äußern zu können. Aufgrund der vorhandenen Experimentiermöglichkeiten und gegebenen Zeitbeschränkungen für eine Dissertation wurden allerdings statt eines Haushalts unsere Büros betrachtet und die Kommandostrukturen auf die Raumcharakterisierung beschränkt.

Analysiert man die Aufgabe der Orientierung durch ein einmaliges Herumführen und eine darauf basierende Befehlsvorgabe näher, so ergeben sich zwei einseitig verknüpfte Probleme:

- Aufbau eines internen Weltbildes ohne Vorgabe von Grundstrukturen – Zimmer können beliebig zugeschnitten, mit beliebigen Tapeten ausgestattet und beliebig möbliert sein.
- Abstimmung des internen Weltbildes auf das globale, relativ allgemein konzipierte Weltbild des Menschen – Zimmer können in offenen und geschlossenen Bauweisen als solche bezeichnet werden, Treppen können gerade, geschwungen oder gewandelt sein, Möbel können die verschiedensten Formen haben und doch gleichmäßig als Tische, Stühle etc. bezeichnet werden.

Es wird dementsprechend zunächst der Aufbau der Planungsebene, der separat betrachtet werden kann, und dann die Gestaltung der Kommunikationsebene, die eng an die Planungsebene angekoppelt ist, aber auch ähnlich mit der heuristischen Ebene zusammen spielen dürfte – wie in Bild 1 angedeutet – behandelt.

3.1 Aufbau einer Planungsebene

Bei einem gekauften Haushaltsroboter ist davon auszugehen, dass die motorischen Fähigkeiten und eventuelle Heuristiken vorab implementiert sind und eine Anpassung an den jeweiligen Haushalt durch Lernen dafür nicht mehr stattfindet. Die Adaption an die Umgebung, d.h. der Aufbau eines internen Weltbildes erfolgt durch sensorische Information, die sinnvollerweise, da so für den mit dem Roboter zusammenlebenden Menschen am einfachsten fassbar, visuell per CCD-Kamera generiert wird.

[18] unterscheidet dabei:

- die präintentionelle Wahrnehmung zum Erlernen der Extraktion von Merkmalen als Verdichtung der aufgenommenen Pixelinformation
- und die intentionelle Wahrnehmung als Erlernen des Einsatzes der Elementarmerkmale für die gewünschte Aufgabe, hier Charakterisierung der Umgebung als verschiedene erfahrene Situationen.

Die Umgebungscharakterisierung liefert bei einer explorativen oder auch geführten Erkundung der Umwelt durch eine Verbindung der klassifizierten Situationen mit Ortsin-

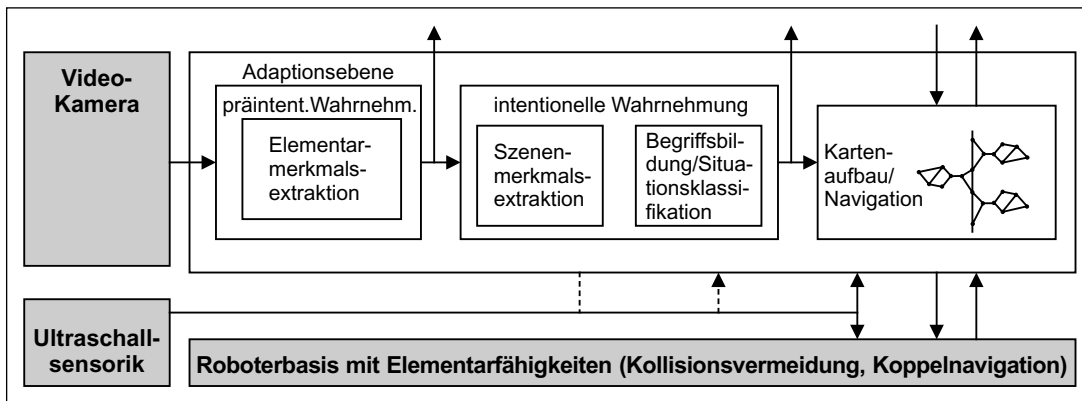


Bild 9: Architektur zum Erlernen eines inneren Weltbildes für „ALEF“ mit Kamera nach [18].




Bild 10: Mehrstufige Aufbereitung des Kamerabildes bei der präintentionellen Wahrnehmung nach [18].

formation aus den durchgeführten Bewegungen einen Graphen, auf dem spätere Planungen basieren können.

Damit ergibt sich als Grundstruktur für die Erstellung des internen Weltbildes einschließlich der Fähigkeit, sich in der erkundeten Umgebung zurechtzufinden (Bild 9).

Die präintentionelle Wahrnehmung hat die Aufgabe einer Segmentierung der Bilder in verschiedene Gebiete, die bezüglich ihrer lokalen Eigenschaften homogen sind, also z.B. von gleicher Textur, Farbe usw. Da dieses Herausfinden elementarer Merkmale für alle Grundstrukturen der Umgebung zunächst unabhängig sein sollte von der Zielsetzung, sich zurechtzufinden, eine Szene zu analysieren oder Objekte zu erkennen, wird es als präintentionell bezeichnet.

Gemäß Bild 10 schlägt [18] dafür ein mehrstufiges Vorgehen vor. Als erstes werden mit Hilfe von in einer Filterbank angeordneten Merkmalsfiltern lokale Pixelelemente extrahiert, wobei verschiedene Ansätze erfolgreich eingesetzt werden können. Dabei ist interessant, dass bei einer Verwendung von Eigenfiltern in einem Innenraum die auf vertikale und horizontale Strukturen ansprechenden Filter dominieren, während bei einem mit Büschen und Bäumen umstandenen Rasenstück sich keine dominierenden Vorzugsrichtungen in der Filterbank bemerkbar machen. D.h. die mehrfache parallele Verarbeitung des Quellbildes ist eine Sensorsignalvorverarbeitung, die in der Lage ist, Umgebungsstrukturen zu betonen.

Eine anschließende unüberwachte Segmentierung durch ein in [18] für ein ständiges Lernen leicht modifiziertes Growing-Neural-Gas-Netzwerk (GNG-Netz) nach [3] liefert zugleich eine Zusammenfassung der Pixelinformation zu einer Zahl N_c von Klassen, die sich in einer Segmentierung des Bildes ausdrückt und einer Robustheit des Sensor-



Bild 11: Robustheit der gemäß Bild 10 ermittelten präintentionellen Darstellung gegenüber kleinen Bildveränderungen [18].

eindrucks gegenüber Störungen des Bildsignals und leichten Veränderungen durch Beleuchtung bzw. Verschiebungen des Kamerastandorts. Bild 11 zeigt dies für eine Roboterbewegung.

Das GNG-Netz ist eine Weiterentwicklung der selbstorganisierenden Karten von T. Kohonen (vgl. z.B. [7]), bei der die Zentren der gewünschten Zahl N_c der Klassifikationsgebiete, die „Neuronen“, nicht vorab vorgegeben, sondern geeignet generiert werden und sich die Klassifikationsgebiete nicht nur in ihrer Größe anpassen, sondern in hochdimensionalen Räumen, wie sie durch die Filterbank entstehen, auch geeignet verteilen. Das GNG-Netz hat sich bei uns bei den verschiedensten Klassifikationsaufgaben sehr bewährt und erscheint mir deshalb wichtiges Werkzeug für den Kasten „Klassifikation“ in Bild 1 zu sein.

Bei der intentionellen Wahrnehmung ist die Zielsetzung maßgeblich für ihre Ausgestaltung. Die zentrale Anforderung der Navigation bei einem mobilen Roboter besteht

darin, Informationen zu beschaffen, die das System benötigt, um Orte mit seinen „Erinnerungen“ vergleichen und wiedererkennen zu können. Ein möglicher, auch vom Menschen weitgehend verfolgt und in der Robotik zumeist benutzter Ansatz ist, den Bildinhalt zu analysieren, ihn zu verstehen und dann die Aussagen mit einem Modell der Wirklichkeit in Beziehung zu setzen. [18] zeigt aber, dass ein Verstehen des Bildinhalts für die Navigation nicht erforderlich ist.

Wesentlich ist es, ein Maß für den Unterschied von Bildern zu definieren. Dazu wird die die Verteilung der Bildinformation in jeder Klasse der präintentionellen Wahrnehmung charakterisierende Segmentierung aus der GNG-Klassifikation durch geometrische Momente bis zur Ordnung 3 gekennzeichnet; die Nutzung höherer Momente bringt keine wesentliche Verbesserung.

Ordnet man nach einer geeigneten Normalisierung alle Momente $m_c^{p,q}$ aller Klassen $c \in [1, N_c]$ in Vektorform an

$$\underline{x} = [m_1^{0,0} \dots m_1^{3,3} \dots m_{N_c}^{0,0} \dots m_{N_c}^{3,3}]^T$$

so bildet der Abstand eines Bildes zu einem Referenzbild

$$\Delta = \|\underline{x} - \underline{x}_{ref}\|$$

ein geeignetes Maß, Bildähnlichkeiten zu beurteilen.

Bild 12 zeigt die Anordnung von Bildern einer Roboterfahrt geordnet bezüglich ihrer Ähnlichkeit zum 1. Bild ge-

mäß diesem Distanzmaß. Ein menschlicher Beobachter würde eine entsprechende Anordnung vornehmen. Durch die geometrischen Momente $m_c^{p,q}$ werden die von der CCD-Kamera erfassten Szenen mittels relativ weniger Merkmale repräsentiert.

Allerdings ist dies eine kontinuierliche Darstellung bei einer Fahrt des Roboters. Um zu einer handhabbaren diskreten Darstellung zu kommen, ist ein weiterer Klassifikationsschritt mit einem weiteren GNG-Netz erforderlich. Damit werden Bereiche des Szenenmerkmalraums, die ähnliche Bildeindrücke beinhalten, zu diskreten Einheiten einer gegebenen Zahl zusammengefaßt. D.h. zeitliche Signalsequenzen werden unüberwacht zusammengefasst, so dass verarbeitbare diskrete Werte entstehen entsprechend den Annahmen zur menschlichen Informationsverarbeitung in [14]. Die Neuronen des GNG-Netzes sind eine endliche Zahl von Referenzbildern – in [18] Situationen genannt – bezüglich der die Ähnlichkeit aktueller Bilder gemessen wird.

Dies ist eine absolut interne Darstellung. Dass sie auch zu für den Menschen verständlichen Charakterisierungen führt, zeigt Bild 13. In diesem Fall wurden durch das GNG-Netz nur zwei verschiedene Situationen unterschieden, die für einen einen Karren schiebenden Menschen als „Freiraum“ und „Engstelle“ verstanden werden könnten.

Hier ist m.E. von Bedeutung, dass der einfache Kasten „Klassifikation“ in Bild 1 für die Bildung von Begriffen




Bild 12: Ähnlichkeitsklassifikation von Bildern gemäß einem die Strukturen in Bild 11 über Momente beschreibenden Distanzmaß ([18]).



Bild 13: Ergebnis einer weiteren Klassifikation: Die interne Einteilung der Bilder aus einer Büroumgebung in zwei Klassen entspricht einer möglichen menschlichen Einteilung in „Freiraum“ und „Engstelle“ ([18]).

(Situationen) für die Planungsebene (und in gleichem Maße wohl auch für die Ebene der Heuristiken) bei komplexen Problemen mehrere Schritte und eventuell mehrere Klassifikationen (hier 2 durch relative aufwendige GNG-Netze realisiert) beinhaltet.

Die Verknüpfung der Wahrnehmung mit der Ortsinformation aus der Koppelnavigation auf der Adaptionsebene aus Bild 9 geschieht in Form einer topologischen Karte, bei der geeignet ausgewählte Orte in der Umgebung Knoten in einem Graphen darstellen, während die Kanten die erfahrenen Übergänge repräsentieren.

Knoten werden angelegt, wenn entweder eine vorgegebene Entfernung gemäß der Koppelnavigation überschritten wird oder aber sich die Überschreitung einer Situationsgrenze ergibt. In jedem Knoten werden über einen Rundumblick mehrere Bilder aufgenommen, um nicht von der Fahrt- und Blickrichtung des Roboters abhängig zu werden. Da die Koppelnavigation nur zur Abstandsinformation zwischen den Knoten benutzt wird, spielt die unvermeidliche Drift bei der so gegebenen Ortsbestimmung keine Rolle.

Bild 14 zeigt den Grundriss unserer für die Experimente mit ALEF genutzten Büroumgebung und die bei einer Führung durch diese Räume angelegten Knoten, allerdings ohne den Rundumblick mit einem nur nach vorne gerichteten Blick.

Da die absolute Ortsinformation durch die Koppelnavigation gegeben ist, führt die fehlende Identifizierbarkeit des Orts infolge der bei verschiedenen Fahrtrichtungen nicht übereinstimmenden Bilder zu einer auf der Drift beruhenden




Bild 14: Ergebnis eines distanz- und bildatengesteuerten Kartenaufbaus mit gerichteter Ortsrepräsentation ([18]).

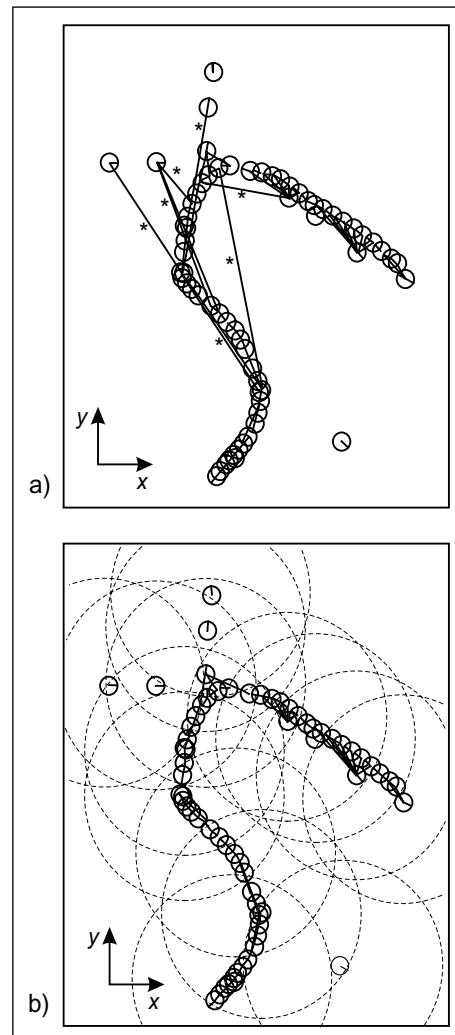


Bild 15: Identifikation des ähnlichsten Bildes beim Nachfahren eines vorher gesehenen Kurses auf der Basis des Vergleichs einzelner Bilder – links – und von drei konsekutiven Bildern mit zusätzlicher Distanzbeschränkung für die Suche nach entsprechenden Bildern – rechts. Die Zuordnung entspricht den Verbindungslinien. Die Fehlzuzuordnungen links werden mit dem für das rechte Bild benutzten Ansatz vermieden ([17]).

den Inkonsistenz. Die scheinbare Wandberührung beruht auf den falschen Ortsdaten, die Kollisionsvermeidung sorgt aber dafür, dass sie in der Realität auch bei falschen Sollvorgaben nicht auftritt.

Der Roboter kann nach einer einzelnen Führung Knotenverbindungen abfahren. Dabei bestimmt er den nächstliegenden Knoten mit dem für die Bildähnlichkeit entwickelten Distanzmaß. In einer Büroumgebung sind aber die erfassten Bilder weitgehend übereinstimmend. Deshalb reicht diese Information nicht vollständig aus, es gibt Fehlidentifikationen – vgl. die Verbindungen von den schwarzen Roboterpositionen zu falschen Knoten in Bild 15a. Dies kann aber leicht korrigiert werden, wenn nur Bilder aus einer lokalen Netzumgebung – weniger als 2,5 m entfernt – und statt eines Bildes drei Bilder verglichen werden (Bild 15b). Für weitere Modifikationen vgl. [17].

3.2 Einbeziehung einer Kommunikationsebene

Die Planungsebene allein erlaubt es dem Roboter nur, interne Zielvorgaben auf der Basis seines internen Weltbildes zu erreichen. Er ist aber nur von Nutzen, wenn er Wünsche seines Besitzers erfüllen kann. Dazu ist sein internes Weltbild auf das menschliche Weltbild und die zugehörige linguistische Kommunikation abzustimmen. Als Beispielauf-

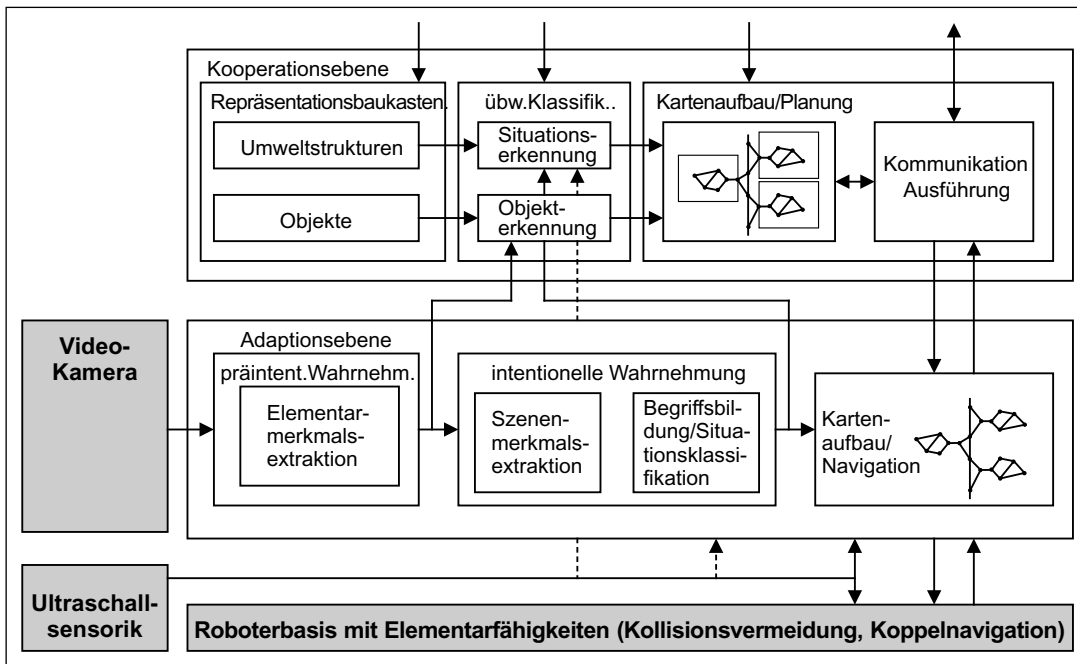


Bild 16: Ergänzung der Architektur aus Bild 9 um eine Kommunikationsebene zum Aufbau einer Korrespondenz zwischen dem internen Weltbild des Roboters und den Vorstellungen des ihn nutzenden Menschen ([18]).

gabe wurde in [18] der Begriff „Raum“ betrachtet. Es ist i.A. ein größeres Gebiet mit Wänden und Türen versehen, in unserem Büro ein rechteckiges Gebiet mit einer (Bürräume) oder mehreren (Flur) Türen. Da der ALEF keine Türen öffnen kann, sind diese im vorliegenden Fall Engstellen. Damit wird es sinnvoll, den Übergang von einem Raum in den nächsten durch eine Engstelle festzulegen, die als Klasse in einem geeignet trainierten GNG-Klassifikator zusammen mit der alternativen Klasse, keine Engstelle = Raum unterschieden werden kann.

Damit ergibt sich für die Kommunikation die in Bild 16 zusammen mit ihrer Verbindung zur internen Roboterarchitektur dargestellte „Kooperationsebene“ von [18]. Das menschliche Weltbild ist im Repräsentationsbaukasten vorgegeben, wobei zweckmäßig zwischen festen Umweltstrukturen und beweglichen Objekten unterschieden wird. Ist das Weltbild ein Raum mit Tür, kann der Klassifikator auf diese Unterscheidung trainiert werden, was einer überwachten Klassifikation entspricht. Entscheidend ist nun, dass die interne Karte nicht, wie im vorangehenden Abschnitt beschrieben, nur intern an Hand eines explorativen oder geführten Verhaltens aufgebaut wird, sondern dass parallel dazu eine Karte aus den Elementen des menschlichen Weltbildes auf der Kooperationsebene entsteht, die durch eine miteingepägte Benennung – hier Raum Nr. x – für Sollvorgaben durch den Roboter genutzt werden kann.

Bild 17 zeigt den so entstehenden Aufbau einer Karte unserer Büroumgebung durch Anlegen neuer Räume beim Passieren einer Tür – die im übrigen von ALEF einfacher über die Ultraschallsensorik als über die Bildverarbeitung erkannt wird – und Bild 18 die Überlagerung dieser Raumvorstellungen bei ALEF mit den wirklichen Büroabmessungen. Man erkennt, dass so selbständig eine für Anweisungen wie „bringe die Post von Raum 4 in Raum 1“ geeignete Vorstellung von ALEF entsteht. Entscheidend ist dabei die parallele Nutzung von interner Sensorinforma-

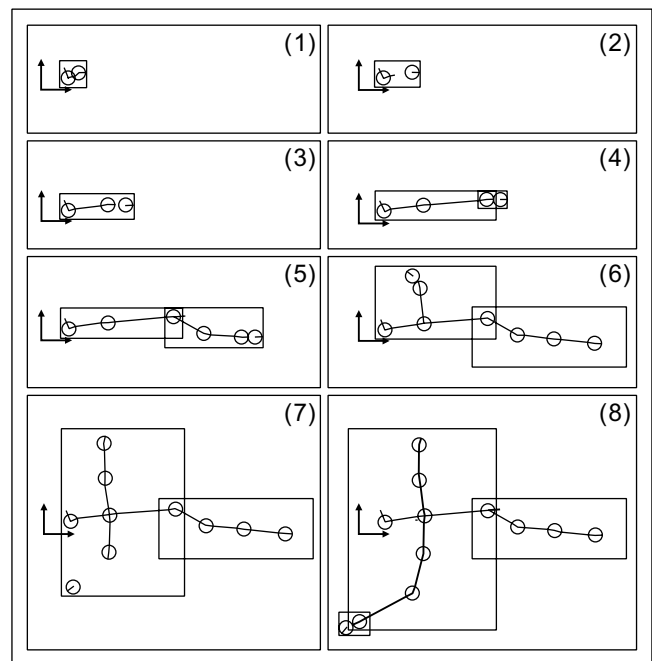


Bild 17: Aufbau einer Karte der Büroumgebung bei der Führung des Roboters durch diese Umgebung unter Nutzung des Konzepts „Raum“ als Freiraum, der durch eine Engstelle mit einem weiteren Freiraum verbunden ist [18].

tion und von von außen vorgegebenen Konzepten, also der gleichzeitige Aufbau des internen und eines auf externe Konzepte abgestimmten Weltbildes.

Auch hier kann man nach einem Pendant in der Informationsverarbeitung des Menschen fragen. Dabei erinnert man sich daran, dass es im Gehirn zwei verschiedene, aber stark vernetzte Teile gibt, die linke Gehirnhälfte, die auf symbolische Charakterisierungen und die Sprache abgestellt ist und die rechte Gehirnhälfte, die sich stärker auf die Koordination der Bewegungen und räumliche Beziehungen spezialisiert hat. Letzteres lernt man als Kind un-




Bild 18: Interne Vorstellung des Roboters über die Räume der Büroumgebung und reale Form der Büroumgebung. Die Namen der Räume müssen von dem mit dem Roboter kommunizierenden Menschen vorgegeben (gelehrt) werden [18].

überwacht, explorativ, während Kategorien und ihre sprachlichen Benennung von anderen, also überwacht gelernt werden. Dass die zugehörigen internen Charakterisierungen durchaus verschieden sein können, erkennt man z.B. an der Unterscheidbarkeit von Farben über ihre Grautöne bei Farbenblinden.

D.h. die Trennung von räumlicher Information und Konzepten in zwei vernetzte Ebenen in [18] scheint in der Spezialisierung der Gehirnhälften eine biologische Entsprechung zu haben. Dabei ist zu beachten, dass das als Planung bezeichnete bewusste Durchdenken von Konsequenzen sich nur im vorliegenden Fall auf auch sensorisch erfassbare, räumliche Information bezieht, i.A. aber auch rein symbolisch ablaufen kann – dem Feld der klassischen KI –, so dass die hier für die Planungsebene vorgestellten Modelle nur Teilmodelle der auf dieser Ebene ablaufenden Vorgänge sein dürften, die aber ingenieurtechnisch nützlich sind.

4 Zusammenfassung und Ausblick

Die Informationsverarbeitung im Nervensystem von Lebewesen basiert auf zwei Elementen, einem Erlernen einer günstigen Architektur im Laufe der Evolution, wobei nach [19] durchaus unnötige Relikte aus Versuchsschritten darin mit enthalten sein können und dem individuellen Lernen in dieser Architektur, das aus den individuellen Erfahrungen des Lebewesens besteht. In der Arbeit wurde versucht, aus Untersuchungen zum Lernen auf dem Gebiet der Robotik, zweckmäßige Architekturen für das individuelle Lernen

abzuleiten. Dabei ist zu beachten, dass zwar im Hinblick auf die Vision eines Dienstleistungsroboters, der eine menschliche Haushaltshilfe zu imitieren in der Lage ist und das notwendige Verständnis seines Verhaltens durch den menschlichen Nutzer, eine gewisse Nachbildung der menschlichen Informationsverarbeitung versucht werden muss, dass aber sowohl aus fehlender Kenntnis als auch aus Aufwandsgründen dieser Ansatz rudimentär bleiben muss: Es konnten weder die sicher im menschlichen Gehirn vorhandene mehrstufige Hierarchisierung noch die Fähigkeit zu abstraktem Denken dabei mit berücksichtigt werden. Es wurde vielmehr die Strukturierung auf das „Denken“ und „Handeln“ in der räumlichen Umgebung abgestellt. Auf die Diskussion von Äquivalenzen, z.B. zwischen Graphenstrukturen und Regelverarbeitungsmethoden der KI wurde dabei nicht mit eingegangen, obwohl die Fähigkeit des Menschen, auch rein abstrakte Gedankengänge zu vollziehen und die gleichmäßige Verarbeitung von räumlich und von abstrakt orientierten Überlegungen in ein- und derselben neuronalen Realisierung dies nahegelegt hätte. [15] gibt Hinweise, dass statt der heute von uns bevorzugten Graphenstruktur auch der regelbasierte Schlussfolgerungsmechanismus der klassischen KI für die Nachbildung der bewussten Informationsverarbeitung erfolgreich genutzt werden kann. Ich glaube aber, dass für das räumlich orientierte Planen und Handeln die Graphenstrukturen geeigneter sind.

Im Einzelnen wurden in Teil I Lernen auf der motorischen Ebene, in Teil II auf der heuristischen Ebene und der Planungsebene diskutiert, ergänzt durch eine Erörterung der Ausbildung einer geeigneten Kommunikationsstruktur durch Abstimmung menschlicher Konzepte auf interne Umweltcharakterisierungen des Roboters am Beispiel eines Komplexes von Räumen.

In Teil I wurden zudem Verbindungen hergestellt zu aktuellen Vorstellungen über Lernen im menschlichen Gehirn basierend auf Vermutungen, welche Areale wie daran beteiligt sind.

Ein wesentlicher Punkt für die Informationsverarbeitung ist die Behandlung sensorischer Information. Dabei ist zu unterscheiden, ob sie für die bewusste oder die unbewusste Signalverarbeitung genutzt wird. Auf der unbewussten motorischen Ebene sind zum Lernen Modelle für die Bewegungsoptimierung aufzubauen. Dies verlangt die möglichst genaue, interpolierende Approximation nichtlinearer Funktionen. Für die bewusste Ebene müssen Sensorsignalsequenzen unterteilt und über eine Klassifikation in diskrete Situationsbeschreibungen überführt werden. Dies bedeutet eine Partitionierung hochdimensionaler Räume, wobei eine vernünftige Trennung im Vordergrund steht, die genaue Grenzziehung aber nicht so bedeutsam ist. Diese Unterscheidung der Aufgaben führt dazu, dass es m.E. angemessen ist, darauf abgestimmte Hilfsmittel einzusetzen, obwohl ein mehrschichtiges Neuronennetz mit Sigmoidfunktionen, das am häufigsten in der Literatur benutzte Multi-Layer-Perzeptron, dies auch, allerdings weniger effektiv, leistet. Für die Funktionsapproximation sind nach

unseren Erfahrungen Ansätze mit lokalen Stützfunktionen am besten geeignet, wie der AMS [16] als Weiterentwicklung des CMAC aus [1]. Für die Klassifikation hat sich der an die Topologie selbsttätig anpassende GNG-Ansatz [3] bei uns am besten bewährt.

Spiegelbildlich zur unterschiedlichen Verarbeitung der Signale für die unbewussten motorischen und die bewussten Verhaltensebenen hat man auf der Seite der Bewegungen die Einzelreaktion, die durch Regelkreise verursacht wird und ganze Bewegungssequenzen, die von den bewussten Ebenen angestoßen werden und als reine Steuerungsabläufe, aber auch als geeignete Vorsteuerungen für die Regelkreise sachgerecht sein können.

Die bewussten Ebenen können als Netzstrukturen lernend aufgebaut werden. Dabei entstehen interne Weltbilder durch unüberwachtes Lernen. Ihre Abstimmung auf die Außenwelt erfolgt durch überwachtes Lernen, wobei neben dem in dieser Arbeit diskutierten parallelen Lernen auch eine nachträgliche Abstimmung der autonom aufgebauten internen Weltvorstellung auf die zur Kommunikation notwendigen Begriffe möglich ist.

Die so gegebene Aufspaltung der bewussten Informationsverarbeitung in die intern orientierten Ebenen der Heuristiken und der Planung und eine Kommunikationsebene weckt Assoziationen zur Aufspaltung der Informationsverarbeitung beim Menschen in eine räumlich orientierte rechte und eine an Kategorien orientierte, linguistische Aufgaben bewältigende linke Gehirnhälfte. Dass selbst Planungsvorgänge, soweit sie räumlich ablaufen, sich in der rechten Gehirnhälfte abspielen können, belegt ein Hinweis in [4], gemäß dem Untersuchungen an Londoner Taxifahrern ergeben hätten, dass deren Routenplanung die rechte Gehirnhälfte aktiviert.

Die weitere Detaillierung der Kommunikationsstruktur und ihre Verknüpfung mit mehr Weltwissen ist m.E. ein interessantes Forschungsgebiet. Dies könnte zu einer Aufspaltung der Planung in räumlich orientierte Planungen und in konzeptorientierte Planungen führen, wobei letztere regelbasiert ablaufen und der linken Gehirnhälfte zugeordnet werden müssten. Auch der bereits in [18] vorgeschlagenen und in Bild 16 mit angeführten Unterscheidung zwischen Umweltstrukturen und Objekten wäre weiter nachzugehen. Außer der Frage anderer Paradigmen, wie etwa der zugrundeliegende Zweck und der Handhabungsmöglichkeiten bei Objekten, könnte sogar eine Weiterentwicklung der präintentionellen Wahrnehmung hier zweckmäßig sein. [8] und [11] geben Hinweise, dass von vornherein auf Krümmungen abgestellte Filtermasken hier sachgerechter sein könnten, wobei vom Ingenieurstandpunkt aus allerdings dann abzuwägen ist, inwieweit die bessere Abstimmung der Filter auf die Umwelt einen eventuellen größeren Aufwand kompensiert.

Eine andere spannende Frage ist m.E., wann und warum Heuristiken aus Bewegungserfahrungen bzw. Planungen entstehen.

Insgesamt hoffe ich, mit dem Aufsatz einige Hinweise gegeben zu haben, wie man sich Strukturierungen für die In-

formationsverarbeitung bei autonomen, mit dem Menschen kooperierenden Systemen vorstellen kann, welche Lernansätze auf welcher Ebene unseren Erfahrungen gemäß eingesetzt werden können und welche Äquivalenzen zur Strukturierung des Gehirns, soweit sie heute verstanden ist, bestehen, wobei allerdings nicht die Nachbildung der Informationsverarbeitung beim Menschen, sondern die effektive ingenieurtechnische Methodik im Vordergrund unserer Überlegungen stand.

Abschließend sollen noch 3 Punkte angemerkt werden:

- Lernen bedeutet Speichern statt Rechnen. Es hat den Vorteil, dass man mit verhältnismäßig allgemeinen, unspezifischen Algorithmen auskommt, wobei Randbedingungen und nichtlineare Effekte automatisch berücksichtigt und nur die wirklichen lokalen Einsatzbereiche – z.B. die real auftretenden Bewegungstrajektorien – dabei festgehalten werden. Die mathematisch-physikalische Modellbildung des Ingenieurbereichs ist dagegen relativ aufwendig und liefert i.A. globale Beschreibungen, die eine vielfach nicht einfache, zusätzliche Berücksichtigung von Beschränkungen erforderlich machen. Jedoch ist dieser Ansatz bei der heutigen Leistungsfähigkeit der Digitalrechner oft die effektivere Implementierung der Roboterfähigkeiten. Abzuwägen ist jeweils der vorab zu leistende Ingenieur- und Implementierungsaufwand gegen die Vorteile einer autonomen Anpassung an die Verhältnisse vor Ort durch Lernen.
- Eine solche Anpassungsfähigkeit ist nicht immer optimal durch Lernen gegeben. In [20] wird am Beispiel der zweiarmligen Handhabung schwerer Objekte aufgezeigt, dass eine Grobmodellierung kombiniert mit einer Parameteradaptation vor Ort dafür geeigneter sein kann als ein direkter Lernansatz.
- Man sollte nicht übersehen, dass die in diesem Aufsatz nicht näher betrachtete Reflexebene die darüber liegenden Ebenen aus Bild 1 erheblich zu entlasten vermag, wobei neben algorithmischen Ansätzen natürlich auch an der neuronalen Informationsverarbeitung orientierte Ansätze hilfreich sein können, wie in [6] am Beispiel der Bewältigung von Bodenebenenheiten für eine Laufmaschine gezeigt wird.

Literatur

- [1] J. S. Albus: Data Storage in the Cerebellar Model Articulation Controller (CMAC) Trans. of the ASME 1975.
- [2] K. Doya: What are the computations of the cerebellum, the basal ganglia and the cerebral cortex? Neural Networks 12 N. 7–8, 1999.
- [3] B. Fritzke: A Growing Neural Gas Network Learns Topologies. Advances in Neural Information Processing Systems 7, 1995.
- [4] T. Huntsberger, J. Rose: BISMARC: A biologically inspired system for map-based autonomous rover control, Neural Networks, 11, S. 1497–1998.
- [5] H. Kiendl: Fuzzy Control methodenorientiert. R. Oldenbourg Verlag, München, Wien, 1997.
- [6] H. Kimura, Y. Fukuda: Adaptive Dynamic Walking of the Quadruped Robot on Irregular Terrain by using Neural System Model. Proc. 1. IFAC Conference on Mechatronic Systems, Darmstadt, Germany, 2000.

- [7] T. Kohonen: Self-Organisation and Associative Memory, Springer-Verlag, Berlin, Heidelberg, sec. edit. 1988.
- [8] N. Krüger: Visual Learning with a priori Constraints, Dissertation Universität Bielefeld, Shaker Verlag, Aachen, 1998.
- [9] A. Kurz: Lernende Steuerung eines autonomen mobilen Roboters – Untersuchungen zum Erwerb sensomotorischer Fähigkeiten und einer für Navigationszwecke nutzbaren Umweltkarte. Dissertation, VDI Fortschritt-Berichte Reihe 8 (428), VDI-Verlag, 1994.
- [10] K. Lorenz: Die Rückseite des Spiegels. R. Piper und Co., München, 1973.
- [11] D. G. Lowe: Perceptual organization and visual recognition. The Kluwer international series in engineering and computer science. Kluwer Academic Publ., Boston 1985.
- [12] Y. Manabe, M. Hattori, S. Takodoro, T. Takamori: Generation of home robots movement based on prediction of human action. Proc. CESA 96 – IMACS Multiconference. S. 210–215, Lille, France, 1996.
- [13] J. Schürmann: Neuronale Netze und die Klassischen Methoden der Mustererkennung. FhG-Berichte – 1991 – Fraunhofer Gesellschaft München, 1999.
- [14] J. G. Taylor: Towards the networks of the brain: from brain imaging to consciousness. Neural Networks 12 N. 7–8, 1999.
- [15] H. Tolle: Autonomieerhöhung durch Imitation menschlicher Intelligenz. at – Automatisierungstechnik, 39(3/4):85–91/109–115, 1991.
- [16] H. Tolle and E. Ersü: Neurocontrol. Learning Control Systems Inspired by Neuronal Architectures and Human Problem Solving Strategies. In M. Thoma, editor, Lecture Notes in Control and Information Sciences No. 172. Springer, Berlin, Heidelberg, New York etc., 1992.
- [17] G. v. Wichert: Selforganizing Visual Perceptron for Mobile Robot Navigation – 2nd Euromicro Workshop on Advanced Mobile Robots, Brescia, Italy 1997.
- [18] G. v. Wichert: Ein Beitrag zum Erlernen der Wahrnehmung: Grundlagen und Konsequenzen für die Architektur autonomer, mobiler Roboter. Dissertation TU Darmstadt, VDI Fortschritt-Berichte Reihe 8 (727), 1998.
- [19] G. C. Williams: Das Schimmern des Polyfisches – Plan und Zweck in der Natur. Spektrum, Akademischer Verlag, Heidelberg, Berlin, 1998 (Original engl. 1997).
- [20] Ch. A. von Albrichsfeld: Ein Beitrag zur selbststellenden Nachgiebigkeitsregelung für kraftschlüssig operierende Roboter. Dissertation TU Darmstadt, Fortschrittberichte VDI Reihe 8 (691), 1998.

Manuskripteingang: 2. Mai 2000.



Prof. em. Dr. rer. nat. Dipl.-Ing. Henning Tolle leitete von 1973 bis 1998 das Fachgebiet Regelsystemtheorie und Robotik am Institut für Regelungstechnik/Automatisierungstechnik der Technischen Universität Darmstadt mit den Hauptarbeitsfeldern Regelkreissynthese, Lernende Regelkreise, Künstliche Intelligenz, Systemautonomie, Robotik und Bildverarbeitung.

Adresse: Technische Universität Darmstadt, Landgraf-Georg-Str. 4, D-64283 Darmstadt, Tel. 06151/16-4990, E-Mail: tolle@rt.e-technik.tu-darmstadt.de

Verfügbar unter
lediglich die vom Gesetz vorgesehenen Nutzungsrechte gemäß UrhG