

Autonomieerhöhung durch Lernen

Teil I: Grundsätzliches und Lernen im motorischen Bereich

Autonomy Increase by Learning Part I: Fundamentals and Learning on the Motor Level

Henning Tolle

Für die Kooperation von Mensch und Roboter – z.B. im normalen Haushalt – sind menschenähnliche Dienstleistungsroboter von Interesse. Für ihre Steuerung/Regelung sind Autonomie und Selbstadaptation durch Lernen notwendig. Diese Arbeit befasst sich mit der dafür geeigneten Architektur und dem Lernen auf ihren unteren, den motorischen Bereich betreffenden Ebenen. Eine Folgearbeit wird Lernen auf den höheren Ebenen behandeln.

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. This paper deals with an adequate control structure and learning on its lower, motor control concerning levels. A second paper will deal with learning on the upper levels.

1 Einleitung

1991 habe ich in der *at* eine Übersicht über Vorstellungen und Erfahrungen meiner Arbeitsgruppe auf dem Gebiet „Autonomieerhöhung durch Imitation der menschlichen Intelligenz“ gegeben [31]. Natürlich war dies auch in den Folgejahren ein Schwerpunkt unserer Arbeiten. Kürzlich bin ich nun in einer „Special Issue“ von „Neural Networks“ [22] auf eine bemerkenswerte Übereinstimmung zwischen unseren, an technisch-methodischen Zweckmäßigkeit überlegungen orientierten Ansätzen und Arbeiten gestoßen, die eine Deutung der im Gehirn stattfindenden Informationsverarbeitung versuchen [8; 20; 30]. Ich nehme dies zum Anlass, orientiert an den dortigen ähnlichen Auffassungen, relevante Präzisierungen unserer Überlegungen und Forschungsprojekte im Überblick darzustellen.

Die Arbeit [31] ging von der Überlegung aus, dass es für den Roboter als menschlichem Assistenten – Service Roboter – wichtig ist, die menschliche Intelligenz weitgehend zu imitieren, um ein selbständiges (autonomes) und zugleich für den mit ihm umgehenden Menschen verständliches Verhalten zu erzeugen. Dabei ging es nicht um eine detailgetreue Nachbildung der Informationsverarbeitung

im Gehirn, sondern es wurde vielmehr versucht, eine Synthese aus verfügbaren rechentechnischen Methoden zur Imitation menschlicher Fähigkeiten und Erkenntnissen über das menschliche Verhalten zu erzeugen. Als wesentliches Ergebnis wurde dabei die in Bild 1 dargestellte Gesamtstruktur vorgeschlagen, wobei das Hervorheben der gelernten Sequenzen damit begründet wurde, dass hier noch die meisten Untersuchungen notwendig zu sein schienen. Entscheidend war nach Auffassung von meinen Mitarbeitern und von mir weniger eine Nachbildung der neuronalen Abläufe im einzelnen, sondern vielmehr die Architektur der Informationsverarbeitung für eine für die Zusammenarbeit mit den Menschen geeignete Dienstleistungs-(Service-)Robotik.

Alle weiteren Arbeiten waren von einer Verfeinerung der entwickelten Architektur bezüglich einer effektiven Informationsverarbeitung und schneller selbständiger Adaption des Wissens durch Lernen aus der Interaktion mit der Umwelt geprägt, in Übereinstimmung mit den Zielsetzungen, wie sie in [22] als aktueller Trend betreffend „Organisation of Computation in Brain-like Systems“ erörtert werden.

In Abschnitt 2 dieses Beitrags wird dementsprechend nach einer auf unseren Erfahrungen seit 1991 basierenden Präzisierung von Bild 1 auf ähnliche Vorstellungen über die In-

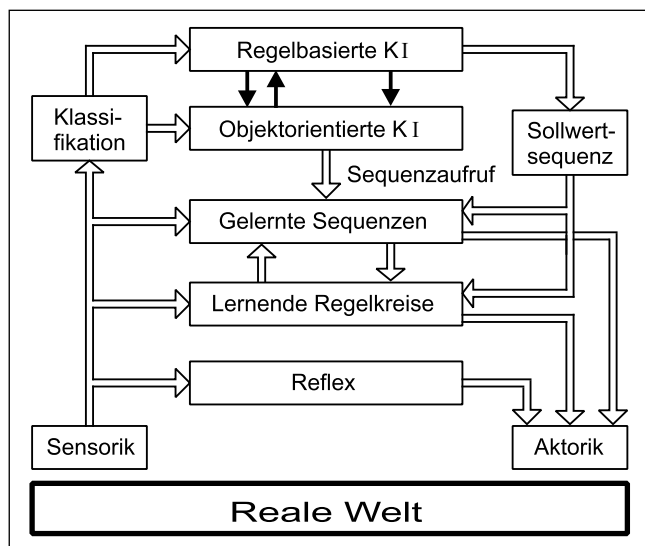


Bild 1: Verhaltensorientierte Gesamtstruktur der neuronalen Informationsverarbeitung in [31]. (Die gelernten Sequenzen waren dabei besonders hervorgehoben, um auf die notwendigen vertiefenden Untersuchungen hinzuweisen).

Informationsverarbeitung im Gehirn aus [22] eingegangen. Wesentliche Punkte aus Abschnitt 2 für die weiteren Ausführungen sind:

- der Einsatz verschiedenartiger Lernparadigmen, die sich nach [8] alle direkt im Gehirn wiederfinden;
- die informationsverarbeitungsrelevante Architektur im Gehirn nach [30], einschließlich der Komprimierung von Sensorsignalsequenzen, die von Taylor als Baustein für den Vorgang der Handlungsauslösung und Planung angesehen wird;
- die Frage der Ausbildung der Kommunikationsfähigkeit und
- das Erlernen von Bewegungssequenzen aus sensorgestütztem Handeln.

Abschnitt 3 behandelt daraus die Nutzung der Lernparadigmen für den motorischen Bereich, Abschnitt 4 die Bewegungssequenzen. In einem weiteren Aufsatz „Autonomieerhöhung durch Lernen“, Teil II werde ich mich dann mit Lernen für die oberen Ebenen von Bild 1 und dem Aufbau der Kommunikationsebene als Mensch-Maschine Schnittstelle beschäftigen. Zur näheren Diskussion der Lernvorgänge werden Untersuchungen aus dem Bereich Robotik betrachtet. Beide Teile schließen jeweils mit einer wertenden Schlussbetrachtung.

[31] ist zum Verständnis der Ausführungen nicht notwendig. Es ergänzt aber die hier vorgestellten Überlegungen in vielerlei Hinsicht.

Abschließend sei noch angemerkt, dass das zentrale Anliegen der jetzigen Aufsätze nicht die detaillierte Darstellung der ingenieurwissenschaftlichen Ergebnisse unserer neueren Arbeiten zur Robotik ist – man findet diese bei Bedarf in der zitierten Literatur. Vielmehr handelt es sich um den Versuch, die Erkenntnisse aus verschiedenen, anwendungsorientierten Untersuchungen bezüglich ihrer grundlegenden Bedeutung für die intelligente Informationsverarbeitung/Automatisierung zu diskutieren.

2 Gehirnstrukturen und Intelligenzimitation

In ihrer Einleitung zum Schwerpunktheft 99 von Neural Networks führen [20] u.a. aus: „Die Untersuchung der Eigenschaften von weitgehend homogenen künstlichen neuronalen Systemen bestehend aus einfachen Knoten führte zu der Erkenntnis, dass Architekturen von Bedeutung sind: Algorithmen generiert durch ein neuronales System spiegeln sich in der zugehörigen Architektur... Die Struktur des Gehirns hat sich so entwickelt, dass möglichst viele Grundmuster der Umgebung eines Lebewesens dazu genutzt werden, sein Verhalten zu optimieren. Daher vereinfacht seine Architektur nicht nur Lernen im Grundsatz durch die Bereitstellung geeigneter Strukturen für die Repräsentation (der Grundmuster), sondern macht auch schnelles und effektives Lernen möglich. Da solche Vorgaben nicht nur festlegen müssen, was gelernt werden soll, sondern auch unter welchen Umständen und in welchem Bezug zu bereits erworbenen Kenntnissen, muss die Architektur aus ineinander verschachtelten Regelkreisen bestehen, die sowohl ihre oberen als auch ihre unteren Ebenen dazu heranziehen“.

Dies entspricht der in meiner Arbeitsgruppe verfolgten Auffassung, dass Effektivität nur durch eine geeignete Unterteilung der Gesamtaufgabe (Architektur) und Verwendung verschiedenartiger Imitationen menschlicher Intelligenz auf den verschiedenen Ebenen erzielt wird.

Der ingenieurmäßige Einsatz verlangt zudem – auch im Hinblick auf die verschiedenartige „Hardware“ bei Lebewesen und in der Technik – dass mathematische Algorithmen und Imitationen der neuronalen Informationsverarbeitung als konkurrierende und sich ergänzende Alternativen angesehen werden.

Meine heutige Auffassung zur generellen Architektur der intelligenten, lernfähigen Informationsverarbeitung ist in Bild 2 dargestellt.

Wesentliche Unterschiede gegenüber Bild 1 sind die etwas andersartige Orientierung der oberen Ebenen und ihre Ergänzung durch eine Kommunikationsebene. Die Verschiebung der „Sequenzen“ aus Bild 1 und ihre genauere Charakterisierung als Bewegungssequenzen sind nicht grundsätzlicher Natur, sondern hängen damit zusammen, dass in [31] die Generierung von (Bewegungs-) Sequenzen als wichtige offene Frage genannt wurde und die Komprimierung von Sensorsignalsequenzen keine Rolle spielte.

Die veränderte Ausfüllung der beiden oberen Ebenen und ihre Ergänzung durch eine dritte Ebene hängt mit unseren Untersuchungen zur Detaillierung der beiden oberen Ebenen für räumlich orientiertes Handeln zusammen.

Während in Bild 1 auf der obersten Ebene die regelbasierten Methoden der künstlichen Intelligenz – KI – als geeignetes Handwerkszeug in Anlehnung an die Imitation menschlicher Intelligenz angesehen wurden, bin ich aufgrund der Arbeiten [15], [21] und [28] heute der Auffassung, dass der direkte Ansatz eines graphisch orientierten

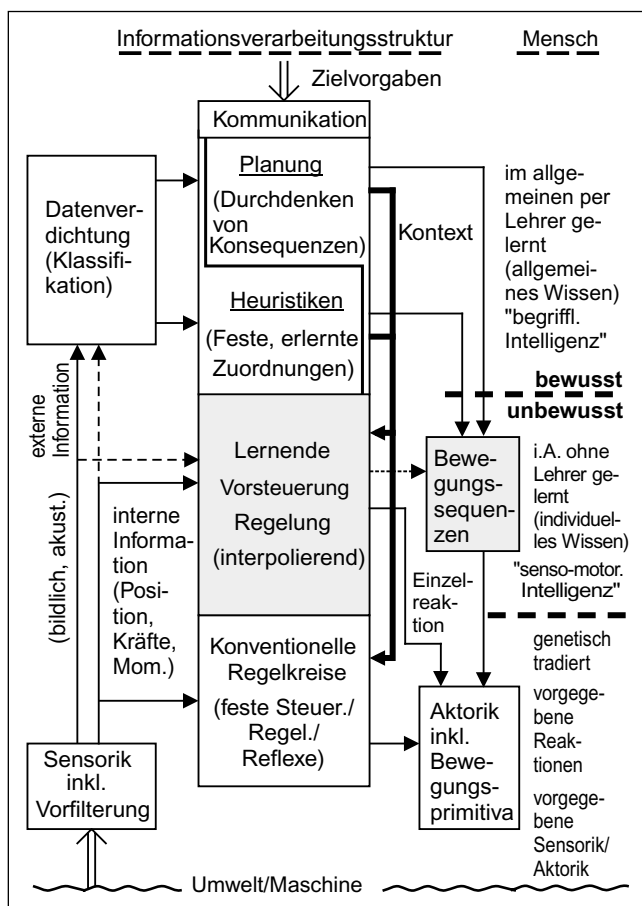


Bild 2: Architektur zur Imitation der menschlichen neuronalen Informationsverarbeitung gemäß den Erfahrungen seit [31]. Schraffiert sind die in diesem Teil 1 näher behandelten Architekturanteile.

Netzes, wie z.B. aber nicht nur eines Petri-Netzes, für die meisten am räumlichen Handeln orientierten automatisierungstechnischen Aufgaben die geeignetste Struktur zur Ablaufplanung bei guter Transparenz für den Nutzer ist. (In seinen Planungen orientiert sich der Mensch auch vielfach an Landmarken – Knoten eines Netzes – und ihren Verbindungen, wie etwa bei einer Wegbeschreibung: Geradeaus bis zur Kirche, dann rechts bis zu einem Platz mit Brunnen usw., wobei verschiedene Wege möglich sind).

Auf der darunter liegenden zweiten bewussten Ebene sind m.E. gelernte Heuristiken eine geschicktere Beschreibungsform als die Benutzung der objektorientierten KI. Ein Beispiel einer solchen Heuristik ist etwa: Wenn Du über die Straße gehst, schau erst nach links und dann nach rechts, ob auch kein Fahrzeug kommt. Im falschen Kontext angewandt, können Heuristiken fatale Folgen haben, z.B. wenn für den Rechtsverkehr entwickelte Heuristiken in England benutzt werden.

In Heuristiken können im übrigen in Ergänzung zu einfachen Feststellungen – wenn kein Auto kommt – auch mehrere Beobachtungen und Erfahrungen einfließen – das Auto blinkt rechts, es wird vor der Stelle, wo ich die Straße überqueren will, abbiegen, evtl. aber auch nicht – einfließen, womit ein Möglichkeitsnetz ähnlich dem Planungsnetz zum Tragen kommt.

Planungsebene und heuristische Ebene können beide direkt mit der Ebene des unmittelbaren Lernens aus Sensorinformation kooperieren, man denke etwa an das geeignete Abknicken der Beine bei einer Riesenwelle. Dies ist durch den Durchgriff rechts durch die Verhaltensebene dargestellt.

Die Kommunikationsebene entstand als Zusatz in Bild 2 zu Bild 1 bei der Suche nach einer effizienten Mensch-Maschine-Schnittstelle für die Planungsebene. Sie kann außer mit der Planungsebene aber auch direkt mit der heuristischen Ebene kooperieren (Planungsanstoß: Geh vom Bahnhof zum Markt; Heuristikenanstoß: Geh über die Straße). Dies ist mit dem linken Durchgriff durch die Planungsebene gemeint.

Man könnte Heuristik und Planung wegen ihrer Ähnlichkeiten und direkten Verbindungen zur Kommunikationsebene und Lernebene auf einer einzigen symbolischen Ebene parallel anordnen. Dies ist in Bild 2 nicht geschehen, da Heuristiken m.E. sowohl als Abstraktionen aus oftmals wiederkehrenden Handlungen als auch als Verdichtungen bei oftmals wiederkehrenden Planungen gebildet werden können und deshalb zwischen beide Ebenen eingeschoben werden sollten. Ihre Entstehung scheint ein offenes Forschungsthema zu sein.

Bild 2 spiegelt sich weitgehend in der Deutung der Informationsverarbeitung im Gehirn durch [30]. Taylor unterscheidet wie in Bild 1 und Bild 2 – auf Kommunikationsaspekte geht er nicht ein:

- ein „bewusstes Ich“
- eine (bewusste) „Handlungsebene“
- eine „motorische Ebene“
- eine „Reflexebene“

die alle zur Steuerung/Regelung des menschlichen Verhaltens notwendig sind und von ihm mit verschiedenen Teilbereichen des Gehirns in Verbindung gebracht werden. Es kann hier nicht auf Einzelheiten dieser sehr detaillierten und auf Beobachtungen der Vorgänge im Gehirn basierenden Überlegungen bzw. der zugehörigen Abläufe eingegangen werden. Interessant ist aber m.E. folgender Gedanke von Taylor:

Die Leistungen des Gehirns, auf einer linguistischen Ebene zu denken und Schlüsse zu ziehen, werden ermöglicht durch die Fähigkeit, Sequenzen neuronaler Aktivität – generiert durch Anstöße von außen oder „Gedanken“ von innen – zu speichern und zu manipulieren. Dies erlaubt, Ideen so hin und her zu schieben, dass vorgefasste Ziele erreicht werden können.

Damit ist m.E. eine einheitliche Beschreibungsform für die Informationsverarbeitung im Gehirn vorgeschlagen worden. Die „Sequenzen“ in Bild 1 waren Bewegungsabläufe, die gemäß bestimmten Eingangssignalen als Gesamtablauf durch die Regeln in Gang gesetzt wurden. Natürlich sind dies im Nervensystem von Lebewesen Sequenzen neuronaler Aktivität. Die Überwölbung des Basisgehirns durch die Großhirnrinde bei den Primaten, die nach [7] für die kognitiven Fähigkeiten des Menschen verantwortlich sein könnte, erlaubt eine überlagerte Ebene, die solche Sequen-

zen ohne die Auslösung von Handlungen verarbeitet. Durch [30] werden zu den in [31] betonten Bewegungssequenzen als Spiegelbild die Sensorsignalsequenzen hervorgehoben. Der Zusammenführung von gelernten einzelnen Reaktionen zu zeitlich ausgedehnten Bewegungssequenzen steht die Zusammenfassung von zeitlich ausgedehnten Sensorsignalsequenzen zu einzelnen Situationscharakterisierungen gegenüber. Dies geschieht durch die in Bild 2 angeführte Klassifikation, die damit – wie skizziert – das echte Pendant zur Sequenzgenerierung ist. Sie wird in Teil II näher diskutiert, während sich die Sequenzbildung aus gelernten Einzelreaktionen in Abschnitt 4 dieses Aufsatzes findet.

Die unterste Ebene der konventionellen Steuerung bzw. Regelung und reflexartigen Abläufe ist automatisierungstechnisch gut fundiert und relativ klar vorgezeichnet. Offen ist dabei nur, was im Einzelfall vorgegeben und inwieweit eine Eingriffsmöglichkeit von oben her vorgesehen wird. Beim Menschen gibt es erstaunlicherweise selbst bei genetisch festgelegten, wichtigen Regelkreisen, wie Blutdruck und Herzschlagfrequenz, Wege zur aktiven adaptiven Veränderung [16; 23].

Besonders vielfältig und für die Automatisierung interessant ist aber die Lernende Vorsteuerung/Regelung, da damit der Ingenieuraufwand für die Systemimplementierung reduziert und eine einfache Nutzung nichtlinearer Leistungsverbesserung erreicht werden kann.

Bei den grundsätzlich möglichen verschiedenen Lernparadigmen unterscheidet man Bestärkungslernen (Reinforcement Learning), überwachtes Lernen (Supervised Learning) und unüberwachtes Lernen (Unsupervised Learning). Doya postuliert in [8], dass verschiedene Teile des Gehirns entsprechend auf diese verschiedenen Lernansätze abgestimmt sind und zwar die Basalkerne (Basal Ganglia) auf das Verstärkungslernen, das Kleinhirn (Cerebellum) auf das überwachte Lernen und die Großhirnrinde (Cortex Cerebri/Cerebral Cortex) auf das unüberwachte Lernen – vgl. zur Systematik und zum Gehirnaufbau die Bilder 3a/3b aus [8].

Der Gedankengang als solcher ist nicht neu – so findet man ausführliche Überlegungen zum Cerebellum als spezialisiertes System für das überwachte Lernen schon in [19] und [1] – wird aber in [8] ausführlich diskutiert und mit verschiedenen Lernstrukturen verbunden.

Ich möchte diese Systematik zum Anlass nehmen, um Erfahrungen mit dem Verstärkungslernen und dem überwachten Lernen auf rein datengetriebener Basis an Hand von [14] in Abschnitt 3 zu diskutieren. Auf das in [14] auch diskutierte überwachte Lernen unter Einschaltung von Wissen werde ich nicht eingehen.

Dafür wird in Teil II das unüberwachte Lernen für die und auf den beiden oberen bewussten Ebenen einschließlich der dafür notwendigen Sensorsignalklassifikation unter Nutzung von [15] und [34] relativ ausführlich besprochen. Ergänzt werden diese Ergebnisse durch eine Erörterung der Notwendigkeit der zusätzlichen Kommunikationsebene und ihrer Gestaltung nach [34].

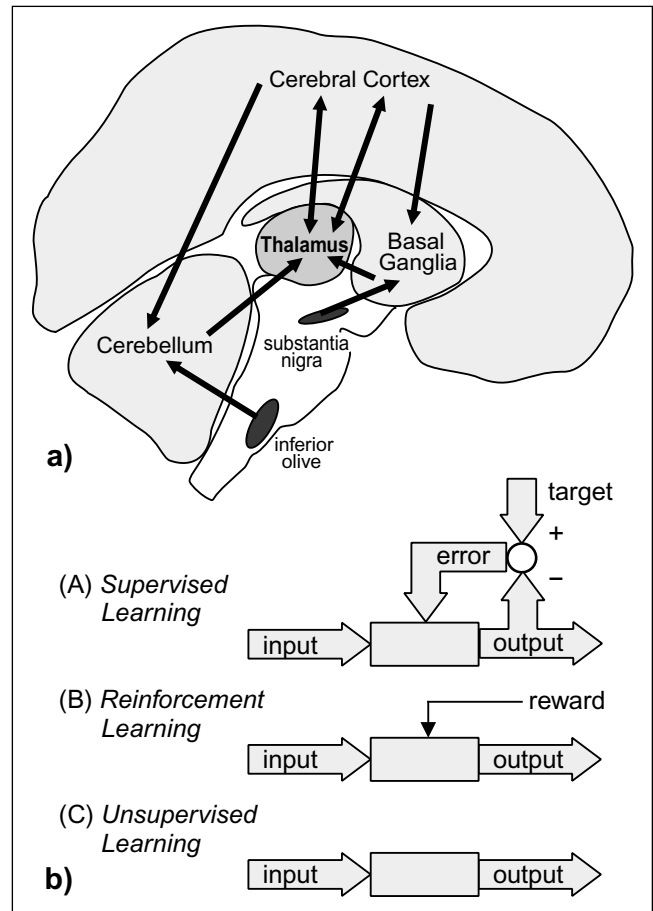


Bild 3: Prinzipielle Lernparadigmen (Bild 3a) und Grundstruktur des Gehirns (Bild 3b), in der nach [8] diese Lernparadigmen verwirklicht sind.

Da, wie die 17 Artikel in [22] zeigen, die Informationsverarbeitung im menschlichen Gehirn zwar inzwischen zum Teil aber keineswegs voll verstanden wird, muss offen bleiben, inwieweit unsere Erkenntnisse über zweckmäßige Vorgehensweisen bei das menschliche Verhalten imitierenden Ansätzen durch biologische Methoden der Informationsverarbeitung gedeckt werden oder ob die verschiedenartigen Realisierungen durch Nervenzellen bzw. elektronische Rechner, oder auch Relikte der Evolution vgl. [36, Kap. 8], wesentliche Unterschiede zur Folge haben. Dies sollte aber nicht davon abhalten, einen aktuellen Erkenntnisstand darzulegen.

3 Lernverfahren für den motorischen Bereich

Ein denkbare Ziel der Dienstleistungs-(Service-)Robotik ist die künstliche Haushaltshilfe. Da der Haushalt vollständig auf den Menschen zugeschnitten ist, ist hierzu ein vollständiger Nachbau des Menschen sachgerecht. Dies ist heute noch nicht möglich, aber man kann Bausteine dafür über grundsätzliche Untersuchungen liefern. Und dies geschieht international und in Deutschland in großem Umfang (vgl. z.B. das DFG-Schwerpunktprogramm „Autonomes Laufen“).

Wir haben dazu in den Arbeiten [13], [24] und [14] mehrfingrige Robotergreifer, [4] und [33] zweiarmiges Handhaben, [27] und [14] Hand-Arm-Auge-Koordination, [21] Informationsverarbeitungsarchitekturen und in [15], [34] Fragen der selbständigen Orientierung in fremden Umgebungen untersucht.

Hier sollen nur einige Ergebnisse aus [14] diskutiert werden.

Bild 4 zeigt eine Zusammenstellung der grundsätzlich zu betrachtenden Aufgaben und Fähigkeiten bei der Steuerung bzw. Regelung eines mehrfingrigen Greifers, Bild 5 die dazu zu untersuchenden Methoden, wobei mathematisch-algorithmische Ansätze Lernansätzen gegenübergestellt sind.

Bezeichnend ist in Bild 5, dass die unterste Ebene entsprechend den genetischen Vorgaben bei Lebewesen zweckmäßigerweise fest vorgegeben, also algorithmisch gestaltet wird. Bild 6 zeigt die zugehörige Struktur der Einzelgelenkregelung.

Für die darüber liegende Ebene der lernenden Regelung/Steuerung, der „senso-motorischen Intelligenz“ – vgl. [26] – hat Kleinmann ganz im Sinne der Unterscheidung in [8] eine Aufspaltung in Bestärkungslernen und überwachtes Lernen vorgenommen, angepasst an die fehlende bzw. vorhandene Verfügbarkeit von globalen Zielsetzungen für die Bewegungen.

Bild 7 stellt schematisch einen Finger und seinen Antrieb durch Seilzüge dar, wobei die zugehörigen Motoren sich im Handwurzelbereich befinden – vgl. Bild 8 –.

Bei dem seilzuggetriebenen Experimentalgreifer wirken sich Bewegungen eines Gelenkes i auf die dahinter liegenden Gelenke j ($j > i$) aus, was als Positionsverkopplung bezeichnet wird. Dieses Phänomen findet man auch bei der menschlichen Hand: Versucht man, nur das mittlere Gelenk eines Fingers zu beugen, so bewegt sich das oberste Gelenk unwillkürlich mit.

Aus der kinematischen Analyse des Greifers folgt die in Bild 9 durch die Verkopplungsfaktoren K_{p12} , K_{p13} , K_{p23} dargestellte Positionsverkopplung.

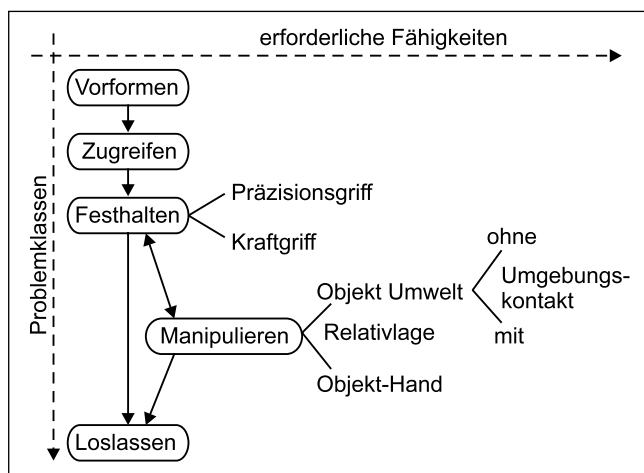


Bild 4: Fähigkeiten und Aufgaben der mehrfingrigen Hand (aus [14]).

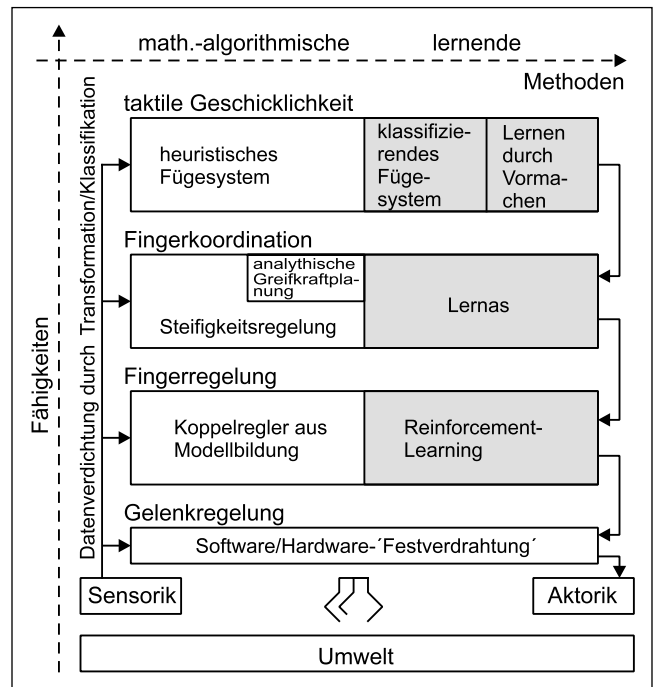


Bild 5: Methodische Ansätze zur Realisierung der Fähigkeiten durch einen mehrfingrigen Robotergreifer [14].




Bild 6: Basisregelung eines Fingergelenks [24].




Bild 7: Aufbau der seilzugbewegten Finger [24].

Man kann eine Verringerung der Verkopplung durch die in Bild 9 auch eingezeichnete Entkopplung erzielen, wobei die Entkopplungsfaktoren K_{kpij} aus den Konstruktionsdaten oder experimentell gewonnen werden können.

Die so erzielte Entkopplung ist jedoch nur angenähert korrekt, da auch nichtlineare Effekte, wie z.B. Reibung, eine Rolle spielen – vgl. Bild 10a/10b. Für nähere Einzelheiten und die zusätzlich zu berücksichtigende Momentenverkopplung vgl. [14].

Die Unterschiede zwischen dem Bestärkungslernen und dem überwachten Lernen, die in Bild 3a skizziert sind,




Bild 8: Die „Darmstadt-Hand“ [24].




Bild 10: Positionssprungantwort für einen Finger ohne Entkopplungsmaßnahmen (Bild 10a) und mit bedieneroptimierter Entkopplung (Bild 10b); Sollwerte $\theta_{1s} = 20^\circ$, $\theta_{2s} = 0^\circ$, $\theta_{3s} = 0^\circ$ ([14]).

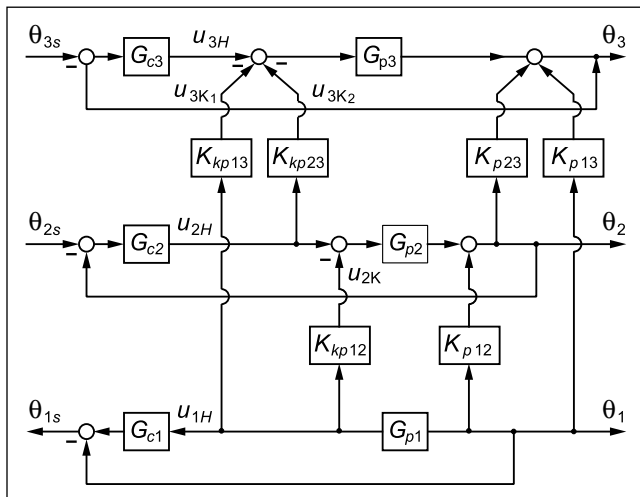


Bild 9: Vereinfachtes Blockschaltbild der Gelenkpositionsregelung eines Fingers mit Verkopplungen K_{pjj} und Entkopplungsreglern K_{kpjj} .

stellen sich genauer so dar: Beim überwachten Lernen ist ein Ziel gegeben, für das eine optimale Aktion ausgewählt, z.B. an Hand eines Prozessmodells ermittelt werden kann. Das Bestärkungslernen geht davon aus, dass so detaillierte Kenntnisse nicht vorliegen. Das Lernen erfolgt auf der Basis des Erfolgs bzw. Misserfolgs von mehr oder weniger zufällig gewählten Lösungsversuchen.

Grundsätzlich gibt es eine Fülle von Ansätzen und Untersuchungen zum Bestärkungslernen, eine Übersicht findet man z.B. in [29]. Hier wird nur auf eine sehr einfache Vorgehensweise eingegangen:

Für die Positionsregelung (für die Momentenregelung hat man genau den gleichen Ansatz) werden in [14] Stellaktionen gemäß ihrem Erfolg für eine Verringerung der Abweichungen zwischen Soll- und Istgelenkstellung bewertet.

Zur Abspeicherung des zu erlernenden Zusammenhangs wurde der lokal interpolierende Speicher AMS, eine effek-

tive Implementierung des „Cerebellar Model Articulation Controller“ von Albus [2] gemäß [32] verwendet.

Gegenüber den häufig zur Funktionsapproximation benutzten unspezifischen neuronalen Netzen (Multilayer Neural Networks) mit ihrer Überlagerung global definierter Sigmoidfunktionen zeichnet sich dieser an der Steuerung der motorischen Fähigkeiten des Menschen orientierte Ansatz – wie der ähnliche Radial-Basis-Funktions-Ansatz, vgl. z.B. [3] – durch nur lokal von Null abweichende Stützfunktionen aus mit dem für den Einsatz in Regelkreisen wichtigen Vorteil der hohen Konvergenzgeschwindigkeit infolge der lokalen Funktionsapproximation. Zudem ist neben einer impliziten Rauschfilterung, einer einfachen Konfigurierbarkeit und einem Trainingsindikator, der Auskunft gibt, ob an einer bestimmten Stelle im Eingangsraum bereits trainierte Information vorliegt, auch ein Konvergenzbeweis für das Trainingsverfahren geführt worden [9; 25]. Der AMS ist deshalb nach unserer Erfahrung für Probleme mit begrenztem, niedrig dimensionalem Eingangsraum der günstigste Ansatz.

Bild 11 zeigt die Struktur des Lernkreises am Beispiel der Positionsentkopplung $j \in \{2,3\}$ mit den Eingängen u_{1H} , u_{2H} gemäß Bild 9. Man benötigt je Entkopplungsaufgabe (Positions-/Momentenentkopplung) je einen Assoziativspeicherbaustein mit zwei Eingängen und zwei Ausgängen, was im Hinblick auf den erforderlichen Rechenzeitbedarf den geeignetsten Lernansatz darstellt.

Im Gegensatz dazu würden Konzepte zum überwachten Lernen mehrere Speicher bzw. Speicher mit einer höheren Eingangsdimension benötigen.

Eine weitere Charakterisierung des benutzten Ansatzes ergibt sich aus der Gegenüberstellung mit experimentell oder konstruktiv ermittelten Entkopplungsfaktoren (Bild 12) Der Lernansatz bestimmt nicht lineare Parameter, sondern Stellaktionen, die das System in verschiedenen Arbeits-




Bild 11: Struktur des Lernkreises für die Positionsentkopplung; $j \in \{2,3\}$. [14].




Bild 12: Vergleich von konventioneller (links) und lernender (rechts) Entkopplung an Hand der Schnittstellen [14].




Bild 13: Positionssprungantwort mit selbsteinstellendem Entkopplungsregler nach 50 Lernläufen; Sollwerte wie in Bild 10 [14].

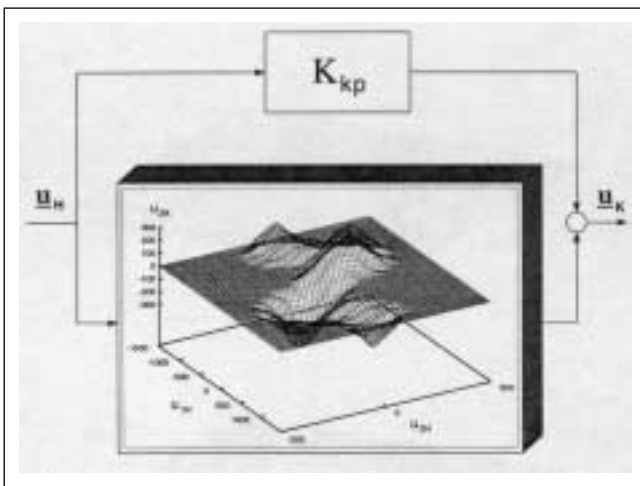


Bild 14: Zweckmäßige Parallelschaltung aus linearem Entkopplungsregler und erlerntem nichtlinearen Entkopplungsanteil; verringert den Lernaufwand um 40 % (Beispiel u_{2k}) [14].




Bild 15: Struktur der Greifer-Streifigkeitsregelung als Kaskade aus Positions- und Kraftregelkreis ([14]).

punkten nichtlinear entkoppeln, wobei der Iterationsprozess durch die Rückführung des Fehlers gesteuert wird. Im Ergebnis erhält man die in Bild 13 gezeigte Verbesserung gegenüber Bild 10b. Die Nichtlinearität der Kompensation erkennt man aus Bild 14. Dabei ist hier statt eines vollständigen Lernens der Entkopplung von dem Erlernen der Differenz zu den linearen Entkopplungsparametern ausgegangen worden. Gegenüber einem vollständigen Erlernen der Entkopplung werden so 40 % des Lernaufwandes eingespart: Es ist also sinnvoll, einfache analytische Vorgaben – einfache genetisch tradierte Voreinstellungen – mit Lernen zu koppeln.

Für das Greifen eines Objekts ist nun über die sachgerechte Bewegung eines Fingers hinaus die Koordination der Finger unter Beachtung des zu greifenden oder manipulierenden Objekts notwendig. Für das stabile Greifen eines Objekts ist eine Steifigkeitsregelung gemäß Bild 15 zweckmäßig [24], die als Steifigkeitsregelung auf Gelenkebene, auf Fingerebene und Objektebene implementiert werden kann. Für einfache Greifaufgaben genügt die Steifigkeitsregelung auf Gelenkebene, wie Hormel in [13] zeigt, indem er für unseren Greifer mit rotationssymmetrischer Fingeranordnung (vgl. Bild 8) und zylindrische Objekte so ausreichende Griffstabilität durch Vorgabe von Greifpunkten auf einem im Objekt liegenden virtuellen Zylinder erzielt.

Für die Objektmanipulation, das Bewegen des Objekts bei gleichzeitigem stabilen Griff reicht die Steifigkeitsregelung auf Gelenkebene nicht aus. Man realisiert als „Steifigkeitsregelung auf Objektebene“ dazu ein Federverhalten bezüglich des mit den Fingerspitzen gegriffenen Objekts im kartesischen Raum. Der Preis dafür ist ein hoher Konfigurierungsaufwand durch eine enge Bindung an den betrachteten Fingerspitzengriff bzw. das gegriffene Objekt. Dies motiviert die Verwirklichung der Fingerkoordination durch eine lernende Regelung.

Allerdings bedingt das Erlernen der Fingerkoordination ohne Fallenlassen des Objekts nun die Einbeziehung eines Prozessmodells mit den zugehörigen Optimierungsmöglichkeiten, d.h. einen Ansatz des überwachten Lernens.

Bild 16 zeigt eine Anwendung des dementsprechend eingesetzten Regelkreises LERNAS [10]: Als Prozess

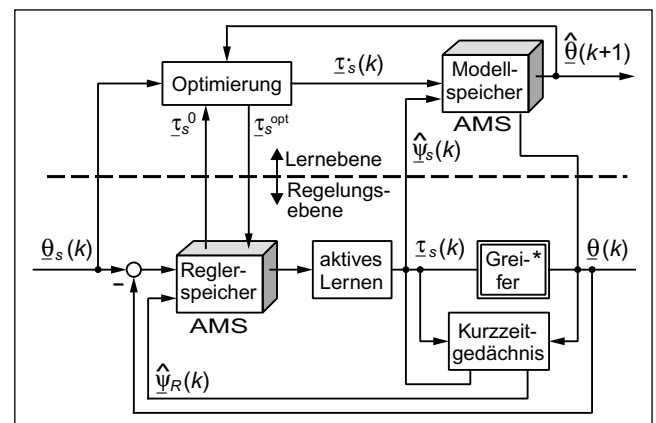


Bild 16: Anwendung von LERNAS auf das Problem der Fingerkoordination.

„Greifer*“ ist hier der Greifer mitsamt seiner Fingerregelung anzusehen. $\tau_s(k)$ sind die Fingergelenksollmomente, $\hat{\psi}_s(k)$ $\hat{\psi}_r(k)$ Abhängigkeiten von früheren Ein- und Ausgängen.

Das „aktive Lernen“ erlaubt ein Training des Modellspeichers und die Optimierung an Hand des Modellspeichers die Auslegung eines günstigen Reglerspeichers unmittelbar bei Betreiben des Prozesses [32]. Bei der Fingerkoordination ist dazu die Basis ein gelenksteifigkeits geregelter stabiler Griff, wobei das aktive Lernen die einzelnen Gelenkmomente zufällig verändert.

Vorteile der lernenden Fingerkoordination sind, dass ohne analytische Modellierung des Greifkontaktes nach ausreichendem Training (<10 Minuten) ein stabiles Festhalten und eine stabile Objektmanipulation gemäß einer vorgegebenen Solltrajektorie erreicht werden bei minimalen Vorgaben:

- virtuellen Greifpunkten
- Formulierung des gewünschten Systemverhaltens in dem Gütekriterium für die Optimierung,
- Einstellung des aktiven Lernens,
- Konfigurierung der (AMS-) Reglerspeicher.

Ohne Neutaining sind dabei auch ähnlich gestaltete Objekte handhabbar und im Gegensatz zu allen konventionellen Fingerkoordinationsmechanismen ist hier die zuvor behandelte Entkopplung für die Einzelfinger nicht erforderlich.

Nachteilig ist, dass ohne die zusätzliche Nutzung einer Bildverarbeitung (die auch Form- und Größeninformation als Kontext liefern würde) zur Ermittlung der Position der Objekte im kartesischen Raum so keine Einbindung in eine Zielvorgabe auf der kartesischen Ebene möglich ist. Dies leistet nur eine analytische Steifigkeitsregelung auf Objektenebene, die zweckmäßigerweise durch eine zugehörige

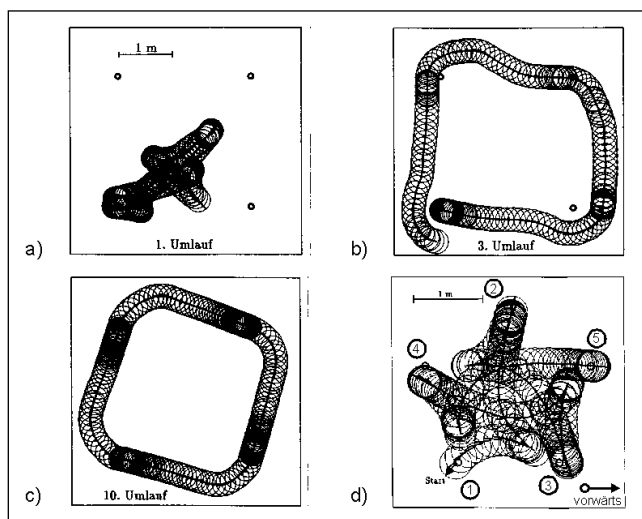


Bild 17: Erlernen der Motorkoordination an Hand der Aufgabe ein Quadrat abzufahren (simuliertes Dreirad): a) vorgegebene Ecken und 1. Umlauf, b) 3. Umlauf; c) 10. Umlauf – das Abfahren des Quadrats ist – soweit kinematisch möglich – perfekt, d) bei vorgegebener Stern-Solltrajektorie als 11. Fahrt fährt das Dreirad streckenweise rückwärts, was es nie gelernt hat [15].

Greifkraftplanung nach [5] und [6] unterstützt wird (Bild 5).

Die Ebene der taktilen Geschicklichkeit aus Bild 5 wird hier – wie schon erwähnt – nicht besprochen.

Statt dessen soll gemäß unseren Untersuchungen betreffend mobile Robotik noch auf die vielfach diskutierte Frage eingegangen werden, ob Lernen nur unmittelbar vorgegebene Verhaltensweisen abbildet oder auch innovatives Handeln in unerwarteten Situationen ermöglicht. Dass letzteres der Fall ist, wurde in [15] am Beispiel der Motorkoordination für einen simulierten mobilen Roboter, ein Dreirad mit lenkbarem Vorderrad und zwei durch eine starre Achse verbundenen Hinterrädern gezeigt. Ihm wurde mit Hilfe von LERNAS beigebracht, seine Motoransteuerung so zu koordinieren, dass ein Viereck abgefahren werden kann, indem viermal rechts ein neues Ziel jeweils senkrecht zur Fahrtrichtung vorgegeben wurde. Die Bilder 17a,b,c geben das Fahrverhalten nach 1maligem, 3maligem und 10maligem Abfahren dieses Rundkurses wieder.

Bild 17d demonstriert, was dann bei der Forderung geschieht, als 11. Umlauf einen sternförmigen Kurs zu verfolgen: Der Roboter fährt zum Erzielen der Spitzen zunächst rückwärts, bis er die richtige Orientierung erreicht hat und schaltet dann auf Vorwärtsbewegung um, ein Verhalten, das er nie gelernt hat.

4 Bewegungssequenzen

Bewegungen können geregelt oder auch gesteuert ablaufen. Insbesondere beim Sport ist es unter Umständen notwendig, so rasch zu reagieren, dass eine Nutzung von Sensorinformation für eine Regelung nicht mehr möglich ist, man denke etwa an den Rückschlag für einen Aufschlag mit über 200 km/Std. beim Tennis. Es muss dann auf der Basis von visuell geschätzten Anfangsbedingungen eine geeignete, erlernte Bewegungssequenz ablaufen. Aber auch bei Aufgaben des Alltags werden häufig Bewegungssequenzen erlernt, die zur Steuerung des Ablaufs oder aber als Vorsteuerung eines Regelkreises genutzt werden. Ein Beispiel ist das Herausnehmen eines großen Photoalbums aus der unteren Schublade einer Kommode. Im Prinzip handelt es sich um die Herausnahme eines Objektes aus einem Kasten mit einer oberen Begrenzung (Hinterschneidung), wie in Bild 18 schematisch dargestellt. In der industriellen Praxis tritt eine solche Aufgabe z.B. bei der Demontage des Objektivs eines Camcorder – Bild 19 – per Roboter auf. In [35] wurde dazu der in Bild 20 gezeigte Regelkreis entwickelt, mit einer Implementierung des Kennfeldreglers als entkoppeltem Fuzzy-Regler, der für alle 6 Freiheitsgrade das gleiche Kennfeld mit zwei Eingängen (Position, Kraft) und einem Ausgang (Robotersollgeschwindigkeit) beinhaltet.

Die bei dem Herausnehmen entstehenden Kontaktsituationen und damit die Lage des Schwerpunkts und die Verdrehung des Objektivs (allgemein eines Objekts bei Herausnahme aus einem Kasten mit einer Hinterschneidung bei




Bild 18: Problem der Herausnahme eines Objekts bei unbekannter Hinterschneidung [35].



Bild 19: Praktischer Hintergrund für Bild 18. Herausnahme des Objekts aus einem Camcorder mit Hilfe eines Roboters bei Vorgabe senkrechten Herausnehmens nach oben und Korrektur dieser Richtung durch taktile Information (Kräfte und Momente aufgrund der Messungen dieser Werte im Roboter-Handgelenk) [35].

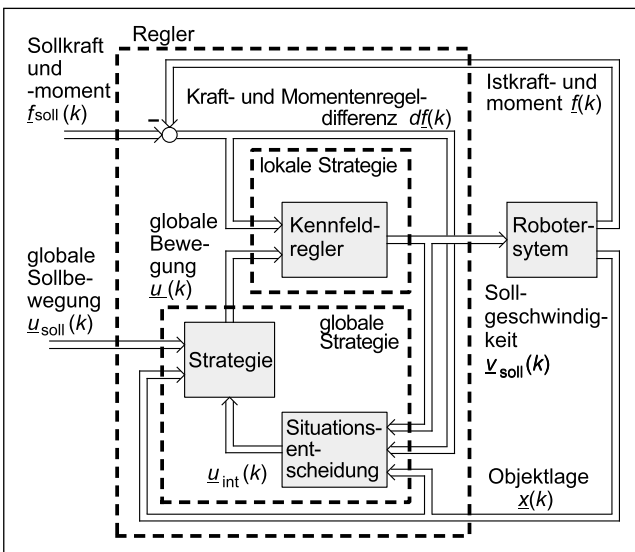


Bild 20: Reglerstruktur nach [35] zur geeigneten Berücksichtigung der taktilen Information für die Aufgaben aus Bild 18, 19.

Vorgabe einer Sollbewegung senkrecht zum Kasten, $-z$ in Bild 18) sind zufällig und die daraus mit dem Regelkreis aus Bild 20 folgenden Roboterbewegungen ebenfalls nicht eindeutig bestimmt, sondern relativ willkürlich, d.h. auch zufällig. Man hat es mit einem doppelt stochastischem Prozess zu tun, wobei die Roboterbewegungen unmittelbar sichtbar, die aus den sie verursachenden Kontaktsituationen sich ergebenden Objektzustände aber unmittelbar verborgen sind.

Damit eignet sich zur Zusammenfassung des Gesamt-ablaufs der Objektivherausnahme der Ansatz eines Hidden-

Markov-Modells [17]. Hidden-Markov-Modelle beschreiben einen doppelt stochastischen Prozess mit n nicht direkt beobachtbaren, zufällig erreichten Zuständen und m daraus zufällig folgenden, beobachtbaren Resultaten in der Form:

$$HMM : (A, B, \pi)$$

Die Elemente a_{ij} der $n \times n$ -Matrix A beschreiben die bedingten Übergangswahrscheinlichkeiten vom Zustand i zum Zustand j , die Elemente $b_i(R_k)$ die bedingten Wahrscheinlichkeiten, dass das Resultat R_k aus dem Zustand i folgt. π ist die anfängliche Zustandsverteilung.

Die Übergangswahrscheinlichkeiten a_{ij} , $b_i(R_k)$ werden aus einer größeren Zahl von Objektentnahmen mit dem Regelkreis aus Bild 20 angenähert durch den z.B. in [12] beschriebenen Baum-Welch Algorithmus ermittelt, der Übergang vom kontinuierlichen Hidden-Markov-Modell zu einem Modell mit endlich vielen Zuständen und Ausgangswerten (diskretes Hidden-Markov-Modell) jeweils mit einer Klassifikation durch ein GNG-Netz (Growing Neural Gas-Netz [11]) vollzogen.

Mit Hilfe des so generierten Modells eines möglichen Spektrums von Gesamt-abläufen kann dann eine möglichst günstige Lösung bezüglich Entnahmezeit und Minimierung der Kontaktkräfte gesucht werden, eine besonders ge-




Bild 21: Verminderung der Summe der auftretenden Kräfte bei der Objektherausnahme an dem in Bild 18 gegebenen Beispiel durch den Übergang von der Regelung nach Bild 20 (Bild 21a) zu einer aufgrund von 10 Beispielentnahmen ermittelten günstigen Entnahmesteuerung (Bewegungssequenz) basierend auf einem diskreten Hidden-Markov-Modell (Bild 21b).

eignete „Bewegungssequenz“. Bild 21a zeigt die typischen Kontaktkräfte bei einer Entnahme mit dem Regelkreis aus Bild 20, Bild 21b das Ergebnis der Optimierung des Entnahmeablaufs mit Hilfe des diskreten Hidden-Markov-Modells. Man erkennt die Verringerung der Kontakte bei gleichzeitiger Verkürzung der Entnahmezeit.

Interessant ist an unseren Untersuchungen zur lernenden Generierung von Bewegungssequenzen m.E. insbesondere folgender Punkt:

- Die aufwendige Generierung günstiger Bewegungssequenzen aus vielen Versuchen ist nur für die rein gesteuerte Bewegung notwendig. Modifiziert man die Entnahmerichtung (-z Richtung in Bild 18), indem man eine Trajektorie entsprechend der Entnahmeerfahrung aus auch nur einem Versuch als Vorsteuerung für den Regelkreis aus Bild 20 (Sollbewegung) nutzt, so ist das Ergebnis bezüglich der Verminderung der Kontaktkräfte und der Entnahmezeit gleich gut, wie wenn man als Vorsteuerung den mit Hilfe des diskreten Hidden-Markov-Modells ermittelten günstigen Entnahmeablauf verwendet: D.h. eine einfache Vorsteuerung genügt, wenn nicht Zeitrestriktionen die Nutzung der Sensorik unmöglich machen; i.allg. ist das Ergebnis so sogar noch besser als das mit der als günstig ermittelten reinen Steuerung erzielte.

Nicht behandelt wurde der Punkt, dass Bewegungsabläufe vielfach aus kleineren Sequenzabschnitten – Bewegungsprimitiva in Bild 2 – zusammengesetzt sind. Ein sehr schönes Beispiel für deren Nutzung findet man in [18]. Ihre autonome Entstehung und Abgrenzung ist aber m.E. noch ein offenes Forschungsthema.

5 Zusammenfassung

Der einfache Ansatz eines Neuronennetzes – Multilayerperceptrons – wird gern als Hilfsmittel benutzt, um schwierige informations- und regelungstechnische Problemstellungen anzugehen mit der Grundvorstellung, dass so auch die menschliche Informationsverarbeitung imitiert wird. In der Realität ist aber ein maßgebliches Element der Effektivität des Gehirns seine Strukturierung, bei der Hierarchisierung und Aufgabenverteilung auf verschiedene Areale eingesetzt werden. Für die Bewältigung komplexer Aufgaben – wie z.B. der Entwicklung einer menschlichen Haushaltshilfe – muss m.E. dem Aufbau entsprechender Architekturebenen und der Nutzung spezifischer Lernansätze besondere Aufmerksamkeit geschenkt werden. In diesem Aufsatz wurden Grundsätze einer solchen Architektur diskutiert und für die motorische Ebene Lernansätze angepasst an die jeweilige Aufgabe diskutiert. Ein zweiter Aufsatz wird sich mit Lernverfahren für die heuristische Ebene und die Planungsebene befassen und zudem das Zusammenbringen der intern erlernten Vorstellungen und der extern vorhandenen, die Zielsetzungen vorgebenden Vorstellungen behandeln. Dies stellt die als Mensch-Maschine-Schnittstelle notwendige Kommunikationsebene dar.

Literatur

- [1] J. S. Albus: Theoretical and Experimental Aspects of a Cerebellar Model. Ph. D. Thesis, Univ. of Maryland, 1972.
- [2] J. S. Albus: Data Storage in the Cerebellar Model Articulation Controller (CMAC) Trans. of the ASME 1975.
- [3] M. Brown, C. Harris: Neurofuzzy Adaptive Modelling and Control. Prentice Hall, 1994.
- [4] H. Bruhm: Untersuchungen zur Handhabung großer Objekte durch Roboter mit kraftschlüssig kooperierenden Armen. Dissertation TH Darmstadt, VDI Fortschritt-Berichte Reihe 8 (280), VDI-Verlag, 1992.
- [5] M. Buss, H. Hashimoto, J. Moore: Grasping Force optimization for multifingered robot hands. Proceed. of the IEEE Intern. Conf. on Robotics and Automation, ICRA 95, Nagoya, Japan, 1995.
- [6] M. Buss and K. Kleinmann: Multi-Fingered Grasping Experiments Using Real-Time Grasping Force Optimization. In Proceedings of the 13th IEEE International Conference on Robotics and Automation (ICRA '96), pages 1807–1812, Minneapolis, USA, April 1996.
- [7] D. Dörner: Problemlösen als Informationsverarbeitung, Kohlhammer Verlag, Stuttgart, 1976.
- [8] K. Doya: What are the computations of the cerebellum, the basal ganglia and the cerebral cortex? in [22].
- [9] D. Ellison: On the convergence of the Albus perceptron. IMA Journal of Mathematical Control of Information, 5, S. 315–331, 1988.
- [10] E. Ersü: On the Application of Associative Neural Network Models to Technical Control Problems. In Varju and Schnitzler, editors, Localization and Orientation in Biology and Engineering, 8. Kybernetik-Kongress, Heidelberg, FRG, March 1983. Springer.
- [11] B. Fritzke: A Growing Neural Gas Network Learns Topologies. In Advances in Neural Information Processing Systems 7 (Hrsg. G. Tesauro, D. S. Touretzky and T. K. Leen) MIT Press 1995.
- [12] B. Hannaford, Lee, P.: Hidden Markov Model Analysis of Force/Torque Information in Telem Manipulation. In: The Int. J. of Robotics Research, Vol. 10, No. 5, pp 528–539.
- [13] M. Hormel: Untersuchungen zum Einsatz neuronaler Modelle in der Regelungstechnik mit Anwendung auf die lernfähige Steuerung eines mehrfingrigen Robotergräfers. Dissertation TH Darmstadt, 1992.
- [14] K. Kleinmann: Lernende Regelung eines mehrfingrigen Robotergräfers – Entwicklung echtzeitfähiger Methoden und Integration mit Industrieroboter und Bildverarbeitungssystem. Dissertation TH Darmstadt, 1996.
- [15] A. Kurz: Lernende Steuerung eines autonomen mobilen Roboters – Untersuchungen zum Erwerb sensomotorischer Fähigkeiten und einer für Navigationszwecke nutzbaren Umweltkarte. Dissertation TH Darmstadt, VDI Fortschritt-Berichte Reihe 8 (428), VDI-Verlag, 1994.
- [16] H. Legewie und L. Nusselt: Biofeedback-Therapie – Lernmethoden in der Psychosomatik, Neurologie und Rehabilitation, Urban und Schwarzenberg Verlag, München-Berlin-Wien, 1975.
- [17] M. Liu, K. Hohm: Discrete Hidden Markov Model based Learning Controller for Robotic Disassembly. In Proceedings of the International ICSC/IFAC Symposium on Neural Computation (NC '98), pages 791–797, Wien, Österreich, 1998.
- [18] O. Lorch, J. Denk, J. F. Scara, M. Buss, F. Freyberger und G. Schmidt: ViGWaM – An Emulation Environment for a Vision Guided Virtual Walking Machine. First IEEE-RAS Int. Conf. On Humanoid Robots, MIT, Cambridge USA 2000.
- [19] D. Marr: A Theory of Cerebellar Cortex. Journ. of Physiology, 202, 1969.
- [20] G. Matsumoto, E. Körner, M. Kawato: Introduction: 1999 Special Issue in [22].

- [21] J. Matthiesen: Informationsverarbeitungs-strukturen zur Erhöhung der Roboterautonomie. Dissertation TH Darmstadt, VDI Fortschritt-Berichte, Reihe 20 (200), VDI-Verlag, 1996.
- [22] Neural Networks – 1999 Special Issue „Organisation of Computation in Brain-like Systems“. ed. E. Körner, G. Matsumoto, M. Kawato – Neural Networks, Vol. 12, N. 7–8 (October/November 1999) Pergamon Press.
- [23] W. Oppelt: Über das Menschenbild des Ingenieurs – eine Bestandsaufnahme und offene Fragen bei der kybernetischen Modellbildung menschlichen Verhaltens. Sitzungsbericht der wissenschaftlichen Gesellschaft an der Johann-Wolfgang-Goethe-Universität Frankfurt am Main, Band XX, Nr. 5, Franz Steiner Verlage, Wiesbaden, Stuttgart, 1984.
- [24] W. Paetsch: Exemplarische Untersuchungen zu mehrfingrigen Robotergreifern: Aufbau -Regelung – Systemintegration. Dissertation TH Darmstadt, VDI Fortschritt-Berichte Reihe 8 (363), VDI-Verlag, 1993.
- [25] P. C. Parks and J. Militzer: Convergence Properties of Associative Memory Storage for Learning Control Systems. Automation and Remote Control, (50/2, part 2): 254–286, 1989.
- [26] J. Piaget: Psychologie der Intelligenz. 8. Auflage, Verlag Klett-Cotta, Stuttgart, 1984.
- [27] M. Seitz: Untersuchung zur Nutzung von Bildverarbeitung für Manipulationsaufgaben in der Robotik. Dissertation TH Darmstadt, Berichte aus der Automatisierungstechnik, Shaker Verlag, 1996.
- [28] B. Strege: Automatische Generierung übersichtlicher Petrinetze und optimaler Abläufe durch Aufspaltung in eine vom Systemingenieur zu implementierende Anlagenbeschreibung und eine vom Facharbeiter vorgebbare Anlagenutzung. Dissertation TH Darmstadt, 1996.
- [29] R. S. Sutton, A. G. Barto: Reinforcement Learning, an Introduction. MIT Press, Cambridge, Massachusetts, 1998.
- [30] J. G. Taylor: Towards the networks of the brain: from brain imaging to consciousness in [22].
- [31] H. Tolle: Autonomieerhöhung durch Imitation menschlicher Intelligenz. at – Automatisierungstechnik, 39(3/4):85–91/109–115, 1991.
- [32] 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.
- [33] C. v. Albrichsfeld: Ein Beitrag zur selbststellenden Nachgiebigkeitsregelung für kraftschlüssig kooperierende Roboter. Dissertation TH Darmstadt, VDI Fortschritt-Berichte Reihe 8 (691), 1998.
- [34] 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.
- [35] A. Weigl: Exemplarische Untersuchungen zur flexiblen automatisierten Demontage elektronischer Geräte mit Industrierobotern – Darmstädter Dissertation – Shaker Verlag, Aachen, 1997.
- [36] G. C. Williams: Das Schimmern des Polyfisches – Plan und Zweck in der Natur. Spektrum, Akademischer Verlag, Heidelberg, Berlin, 1998 (Original engl. 1997).

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

Zeitgemäß, schnell und bequem recherchieren:

at online

Von Heft 01/2000 an: alle Beiträge im Volltext als pdf-Dateien.

Für Abonnenten der Online-Ausgabe.

Von 1999 an: die Abstracts aller veröffentlichten Beiträge. Kostenlos.

Suche, Informationen, Bestellmöglichkeit:

www.oldenbourg-online.de