

KI und Neuroinformatik

Katharina Morik
Universität Dortmund
Fachbereich Informatik, LS VIII

Einige Gedanken, die schon früh innerhalb der Künstlichen Intelligenz (KI) formuliert wurden, werden jetzt erneut vorgetragen, allerdings unter der Überschrift "Neuroinformatik":

- 1) einfache, kleine Einheiten können durch ihre Interaktion untereinander komplexes Verhalten zeigen - so wurden Produktionsregeln und semantische Netze eingeführt und so wird jetzt für neuronale Netze argumentiert;
- 2) einfache Regeln können in Interaktion mit einer komplexen Umwelt komplexes Verhalten ergeben - dies illustrierte Simon (1969) mit seinem berühmten Beispiel der Ameise und jetzt wird der Gedanke von der Neuroinformatik vorgebracht;
- 3) erst durch Lernen kann wirklich intelligentes Verhalten entstehen - diese Einsicht wurde schon von Turing (1959) formuliert und stand Pate bei den Expertensystemen (Simon 1978) wie auch bei den neuronalen Netzen (Rosenblatt 1959).

Das Beispiel der Ameise zeigt Gemeinsamkeit wie auch Verschiedenheit des Beschreibungsansatzes der KI und des Konstruktionsansatzes der Neuroinformatik. Der Pfad einer Ameise ist am besten durch die Regel "gehe immer den untersten Weg in ungefähre Richtung auf das Ziel" zu beschreiben. Die einfache Regel zusammen mit der jeweiligen Bodenbeschaffenheit der Umwelt erzeugt komplizierte Ameisenpfade. Die Komplexität liegt in der vorhandenen Umwelt - das System kann einfach bleiben. Dies ist eine gemeinsame Annahme von KI und Neuroinformatik. Wenn die Komplexität der Umwelt von einfachen Systemen ausgenutzt werden soll, müssen diese über Wahrnehmungsfähigkeiten verfügen. Deshalb standen am Anfang der KI so viele Systeme mit "perception" im Namen ("elementary perceiver and memorizer"- EPAM (Feigenbaum, Simon 1963), "Perceptron" (Minsky, Papert 1969)). Die Geschichte dieser beiden KI-Entwicklungen illustriert die oben angeführten Punkte.

EPAM

In seiner Doktorarbeit stellte Feigenbaum mit EPAM ein Gedächtnismodell vor, das insbesondere den Positionseffekt (erste und letzte Einheiten einer zu memorierenden Silbenmenge werden von Personen am besten erinnert) modellieren sollte. Gedächtnisinhalte sind in einem Diskriminationsnetz gespeichert, dessen Kanten Tests und dessen Nachfolgeknoten die Elemente sind, die noch im Zugriff sind, wenn der Test bestanden wurde. Die Blätter des Netzwerks sind vollständige Gedächtniselemente. Das Netz wird zum Abspeichern und Auffinden von Informationen genutzt. Wenn zum Beispiel ein Wort aufgefunden werden soll, so nimmt man zuerst den ersten Buchstaben als Test und erreicht so einen Knoten, von dem aus nur noch Wörter mit diesem Anfangsbuchstaben erreichbar sind. Dann wird der letzte Buchstabe als Test verwendet und man erreicht einen Knoten, von dem aus nur noch Wörter mit dem vorgegebenen Anfangs- und Endbuchstaben erreichbar sind. Von diesem Knoten aus wählt man die Kante mit dem ersten der mittleren Buchstaben und so fort, bis man bei dem gesuchten Wort als Blatt des Netzwerks angekommen ist. Dieses einfache Modell wurde weitergeführt, so daß die Kanten die aktuelle Situation in der Umwelt abgleichen und die Blätter auf relevante Handlungen in der Situation verweisen. Dies Modell von Verhalten in Situationen wurde dann komprimierter und verständlicher in Form von Produktionsregeln dargestellt. Kompiliert man diese Produktionsregeln (etwa mit dem RETE Algorithmus (Forgy 1982)), erhält man wieder ein Diskriminationsnetz ähnlich dem des EPAM. Der Repräsentationswechsel ergibt nun eine feste Kontrollstruktur, mit der eine Menge einfacher, gleichartiger Regeln interpretiert wird. Das Systemverhalten ergibt sich aus dem Zusammenwirken dieser Regeln in einer konkreten Situation. Dies illustriert Punkt 1.

Nur die relevanten Aspekte der Situation werden in den Bedingungen erfaßt, nur einem Ziel nützliche Veränderungen werden an der Situation vorgenommen. Es ist dem damaligen Stand der Technik und den ersten Anwendungsgebieten geschuldet, daß die Situation in Form von Daten vorlag und manipuliert wurde. Dies hat dann zu dem Mißverständnis geführt, die KI würde "autistische" Systeme ohne Bezug zur Umwelt entwerfen und lediglich Symbole manipulieren. Aber natürlich ist Wahrnehmung nicht nur auf die der physikalischen Umwelt beschränkt. Auch in der Kommunikation wird wahrgenommen. Auch ein Gesprächspartner ist Umwelt. Auch aus der Interaktion mit Benutzern kann Wissen über die Welt gewonnen werden, so daß es nicht mühsam dem System eingegeben werden muß. Prinzipiell wurde nicht daran gedacht, die Umwelt vollständig zu repräsentieren und dann diese Repräsentation durch die Regeln zu verändern. Die Situation konnte durch ohnehin als Daten vorliegende Prozeßdaten dem System zugänglich sein oder durch Anfragen an den Benutzer, der die Umwelt wahrnehmen kann, verfügbar

gemacht werden. Die Handlungen konnten direkte Steuerungen von Maschinen sein oder als Ratschläge an den Benutzer dazu führen, daß dieser die Situation verändert. In beiden Fällen muß nicht die komplexe Umwelt repräsentiert werden, sondern lediglich eine Menge von Bedingungen (im Ameisenbeispiel etwa: geht es hier herauf oder herunter?) und von Handlungen (im Ameisenbeispiel etwa: gehe jetzt nach vorn). Bei verbesserten Wahrnehmungs- und Handhabungssystemen kann auch die Erfassung und Veränderung von Situationen verbessert werden. Dies ist allerdings keine prinzipielle Neuerung.¹ Dies illustriert unseren Punkt 2.

Das Systemverhalten kann durch neue Regeln bei gleichbleibender Interpreterstrategie verbessert werden. Insbesondere können neue Regeln gelernt werden. Es ist wesentlich einfacher, den Erwerb von Regeln zu modellieren als etwa den Erwerb eines Programms, das ja Kontrollstruktur, Daten und Veränderung der Situation ununterscheidbar enthält. Insofern stand also der Gedanke an die Erlernbarkeit intelligenten Verhaltens am Anfang dessen, was dann unter dem Schlagwort "Expertensysteme" zu einem Anwendungsbereich der KI wurde. Heute gehören Lernverfahren entweder bereits zur Expertensystemhülle oder werden als Produkt angeboten, das aus Beispielen Regeln lernt, die dann von verschiedenen Systemen genutzt werden können. Dies illustriert unseren Punkt 3. Schon früh wurden also die oben angeführten drei Punkte innerhalb der KI diskutiert und so zeigen sich Gemeinsamkeiten zwischen Neuroinformatik und KI.

Perceptron

Auch das zweite Beispiel, das Perceptron, zeigt die Berücksichtigung der oben angeführten Gedanken innerhalb der KI. Es ging damals um die Modellierung von Neuronen oder Gehirnfunktionen. Mc Culloch und Pitts schrieben 1943 "A Logical Calculus of the Ideas Immanent in Neural Activity", Minsky promovierte 1954 über "Neural Nets and the Brain Model Problem" und Rosenblatt schrieb 1962 über "Principles of Neurodynamics". Die Beschäftigung mit neuronalen Prozessen und dem Gehirn ist also in der KI nichts Neues. Entwickelt wurden Netzwerke, deren Einheiten reelle Zahlen als Eingabe erhalten und mittels einer Ausgabefunktion in Abhängigkeit von ihrem Zustand eine reelle Zahl über gewichtete Verbindungen an die Nachbareinheiten weitergeben. Als wesentlich wurde bei diesem numerischen Repräsentationsformalismus herausgestellt, daß die vielen einfachen, voneinander unabhängigen Einheiten erst durch ihr Zusammenwirken das Systemverhalten bewirken (Punkt 1). Die Interaktion mit der Umwelt ist beschränkt: Wahrnehmungen und Handlungen werden als Zahlenvektoren codiert. Für einige Anwendungsfelder wie etwa die Muster gesprochener

Sprache ist diese Codierung naheliegend. Als wichtigste Eigenschaft der Netzwerke wurde ihre Lernfähigkeit angeführt (Punkt 3). Allerdings zeigte sich, daß die frühen Ansätze, nämlich feedforward Netze mit nur zwei Ebenen, schon so einfache Funktionen wie XOR nicht erlernen können (Minsky, Papert 1969). Gerade die so sehr beschränkte Lernfähigkeit des Perceptrons war der Grund, daß die Beschäftigung mit biologischen Metaphern aufgegeben wurde. Als Modell für das komplexe biologische Neuron können die einfachen Einheiten neuronaler Netze ohnehin nicht gelten. In den 80er Jahren machte die Einführung weiterer Ebenen (hidden units) in das Netzwerkmodell diesen Repräsentationsformalismus mächtig genug, um zum Beispiel die XOR-Funktion zu lernen. Damit fand auch die biologische Metapher wieder Eingang in die Diskussion - diesmal in Abgrenzung von der KI. Auch die neueren Verfahren können allerdings nicht in Anspruch nehmen, Modelle biologischer Neuronen zu sein.

Maschinelles Lernen

Da die Lernfähigkeit (Punkt 3) ein zentraler Diskussionsgegenstand bei Neuroinformatik wie auch KI ist, soll auf dieses Gebiet etwas ausführlicher eingegangen werden. Das maschinelle Lernen ist ein zentraler Bereich der KI. Lernfähige Programme sind seit mehreren Jahren auf dem Markt und werden häufig für die Gewinnung von Entscheidungsbäumen oder den Erwerb von Regeln für Expertensysteme genutzt. Die Forschung entwickelt Verfahren für verschiedene Repräsentationsklassen und verschiedene Lernaufgaben. Neuerdings wird auch der interdisziplinäre Bezug zur Psychologie ernst genommen (z.B. gibt es ein entsprechendes Graduiertenkolleg an der Universität Freiburg). Die Beschäftigung mit maschinellem Lernen dient zum einen dazu, Computersysteme benutzerfreundlicher zu machen: es sollen nicht alle Regeln, die ein regelbasiertes System benötigt, von Menschen eingegeben werden müssen. Zum anderen sollen Computer Aufgaben erfüllen können, die auf einer eingeschränkten Lernfähigkeit beruhen. So sollen etwa in großen Datensammlungen Gesetzmäßigkeiten entdeckt werden oder es soll eine optimale Reihenfolge von Entscheidungen für die Klassifikation von Objekten bestimmt werden. Diese beiden praktischen Zielsetzungen werden durch theoretische ergänzt. Ein lernendes System stellt eine Beschreibung von einer Vorstellung von Lernen dar. Ein formales Modell für eine Auffassung von dem, was Lernen ist, kann nun mit formalen Methoden untersucht werden, die auf nicht formalisierte Auffassungen nicht anwendbar sind. Ziel der formalen Lerntheorie (computational learning theory) ist es nun, Eigenschaften verschiedener formalisierter Lernaufgaben genau zu fassen. Ziel der interdisziplinären Arbeiten ist es, formale Beschreibungen für natürliche Lernprozesse (bei Menschen, Tieren) zu finden.

Die klassischen Lernverfahren, von denen einige bereits zu Produkten geworden sind, lernen Regeln oder Entscheidungsbäume aus Beispielen (top down induction of decision trees - TDIDT). Sie arbeiten mit einer Attribut-Werte-Repräsentation. Bei dem bekannten Verfahren ID3 (Quinlan 1986) wird aus Beispielen heuristisch ein Entscheidungsbaum gelernt, der dann in Produktionsregeln überführt werden kann (Quinlan 1987). Eine Verbesserung dieses Verfahrens ist CN2 (Clark, Niblett 1988). Eine sorgfältige statistische Fundierung und Angaben zur Verwendung verschiedener Algorithmen dieser Klasse liefern Olshen und Kollegen (Olshen, Breiman, Friedman, Stone 1984). Schon diese Verfahren liefern etwa gleich gute Ergebnisse wie neuronale Netzwerke. So berichten Weiss und Kapouleas (1989), daß neuronale Netze mit Backpropagation schlechter lernten als Entscheidungsbaumlernverfahren. Ausführliche Vergleiche ergaben dasselbe schlechtere Abschneiden von neuronalen Netzen gegenüber statistisch basierten Verfahren (Weiss, Kulikowski 1991). Fisher und McKusick (1989) verglichen ID3 mit Backpropagation und stellten fest, daß das neuronale Netz länger braucht, um zum Lernergebnis zu kommen. Dabei wurde nicht nur erfaßt, wieviele Beispiele wie oft präsentiert werden mußten (ein Maß, bei dem neuronale Netze ohnehin schlecht abschneiden), sondern auch wie lange es dauert, ein Beispiel zu verarbeiten (ein Maß, das eigentlich für neuronale Netze günstig ist). Allerdings war die Korrektheit der Lernergebnisse vor allem bei verrauschten Daten bei neuronalen Netzen besser als bei dem ursprünglichen ID3-Algorithmus (Fisher, McKusick 1989).² Kriterien wie die Verständlichkeit der Lernergebnisse und der Aufwand, der für die Aufbereitung der Beispiele nötig ist, fanden in diesen Vergleichsstudien allerdings keine Beachtung.

Diese Lernverfahren - sowohl neuronale Netze wie auch TDIDT-Verfahren - sind in verschiedener Hinsicht beschränkt:

- Ihre Repräsentation (Attribut-Werte) erlaubt es nicht, Relationen direkt auszudrücken. Während bei der Relation zwischen Autobesitzer und Automarke `besitzt(<Person>, <Auto>)` beispielsweise mit anderen Relationen die speziellen Personen und Autos näher beschrieben werden können - etwa `einkommen(<Person>, <Betrag>)`, `hoch(<Betrag>)` und `hersteller(<Auto>, <Firma>)`, `nationalitaet (<Firma>, <Nation>)`, `alt(<Auto>)` - wird bei der Attribut-Werte-Darstellung Person oder Auto als Objekt ausgewählt, das weiter attribuiert werden kann, die andere Klasse wird lediglich als Wert angegeben, der nur rudimentär durch Taxonomien beschreibbar ist - etwa `besitzt(<Person>, <AutoHersteller>)`, `deutsch: {vw, mercedes}`. In diesem Beispiel kann ein spezielles Auto (etwa als `alt`) nur in der relationalen Darstellung beschrieben werden, in der Attribut-Werte-Darstellung gibt es nur Autoklassen.

- Die Repräsentation des Lernergebnisses kann nicht von den Verfahren selbst interpretiert werden, so daß ein Lernen im Kreislauf (closed loop learning) ausgeschlossen wird.
- Hintergrundwissen kann nicht berücksichtigt werden - nur Beispiele werden als Eingabe akzeptiert. Auch dies verhindert natürlich ein Lernen im Kreislauf.

In der Forschung werden Lernverfahren für weitere Repräsentationsklassen, insbesondere verschiedene Einschränkungen der Prädikatenlogik, entwickelt. Beim logikbasierten Lernen können einfache Prologprogramme oder Relationen oder Begriffe der Termsubsumptionsformalismen (auch: terminological logic oder description logic genannt) gelernt werden.³ Diese Repräsentationsformalismen erlauben eine einfache, kompakte und leicht verständliche Darstellung von Sachverhalten. Die Ansätze des *induktiven logischen Programmierens* zeichnen sich weiterhin dadurch aus, daß das Lernergebnis vom System interpretiert werden kann. Schließlich wird Hintergrundwissen (möglicherweise selbst gelernt) beim Lernen berücksichtigt. Damit wird Lernen in einen Zusammenhang mit bereits Gelerntem oder Vorgegebenem gesetzt und der Bezug zu natürlichem Lernen hergestellt: natürliches Lernen findet immer in einem solchen Zusammenhang (und nur unter Laborbedingungen auf Beispiele beschränkt) statt. Der Anwendungsbereich solcher Systeme, die Lernen und Problemlösen eng miteinander verschränken,⁴ umfaßt den Aufbau und die Wartung von Wissensbasen, die Analyse von großen Datenmengen für die Datenbankmodellierung sowie -wie weiter unten ausführlicher dargestellt - die Unterstützung von Robotersystemen.

Für Anwendungen in Entscheidungsunterstützungs-, Diagnose- oder Konfigurationssystemen ist die leichte Kontrollierbarkeit der Lernergebnisse durch den Benutzer wichtig. Daher muß die Repräsentation des Lernergebnisses möglichst nah an den dem Benutzer geläufigen Darstellungen sein. Eingeschränkte Prädikatenlogiken haben sich in dieser Hinsicht bewährt. Die Kontrollierbarkeit erfordert aber nicht nur die Verständlichkeit des Lernergebnisses, sondern auch die Transparenz des Lernverfahrens. Formale Eigenschaften des Verfahrens müssen geklärt werden. So ist festzustellen, ob ein Verfahren die *speziellste Generalisierung* oder die *generellste Diskriminierung von Klassen* für eine Menge von Beispielen bei gegebenem Hintergrundwissen findet. Gibt es immer genau ein solches Lernergebnis oder mehrere? Beim logikbasierten Lernen arbeitet man daran, das Lernergebnis bezüglich einer gegebenen Menge von Beispielen zu charakterisieren. Man geht nicht davon aus, daß die Verteilung der Beispiele der realen Verteilung der Klassen entspricht. Man geht auch meist nicht davon aus, daß die Beispiele nach und

nach vollständig präsentiert werden. Die theoretischen Arbeiten streben vielmehr an, dem Benutzer zuzusichern, daß das Verfahren die (eine) speziellste Generalisierung (generellste Diskriminierung) für die gegebenen Daten liefert und daß das Lernergebnis mit dem Hintergrundwissen und den Beispielen konsistent ist (Kietz 1993). Auf diese Weise wird das Lernverfahren transparent und einschätzbar.

Theoretische Resultate über die Lernbarkeit geben die Komplexität von Lernaufgaben - seien sie im logischen Paradigma oder in dem neuronaler Netze formuliert - an. Die Lernaufgaben abstrahieren von dem Subjekt des Lernens (Mensch, Tier, Maschine). Sie formalisieren (teilweise) unsere Vorstellung vom Lernen. Eigenschaften verschiedener Lernmodelle können anhand von deren Formalisierung untersucht werden. Die aktuelle Forschung arbeitet daran, ein Gesamtbild der Schwierigkeitsgrade verschiedener formalisierter Lernaufgaben zu erstellen⁵. Diese Ergebnisse zurückzubeziehen auf natürliches Lernen steht noch aus. Inwieweit die Komplexität formaler Lernaufgaben auch dem Schwierigkeitsgrad entsprechender Lernaufgaben für Lebewesen entspricht, wurde bisher noch nicht untersucht. Auch wäre es interessant festzustellen, ob entwicklungsgeschichtlich spätere Lebensformen schwierigere Lernaufgaben zu lösen imstande sind als frühere Lebensformen.

Die Frage des Spracherwerbs zeigt, daß der Bezug zwischen Lernbarkeits-ergebnissen und natürlichem Lernen nicht einfach ist. Formal konnte gezeigt werden, daß aus der vollständigen Präsentation positiver und negativer Beispiele reguläre und kontextfreie Sprachen identifiziert werden können. Kinder lernen ihre natürliche Sprache, die vermutlich komplexer ist als kontextfreie Sprachen, überwiegend aus positiven Beispielen. Aus positiven Beispielen allein sind aber nicht einmal reguläre Sprachen identifizierbar. Entspricht die Lernaufgabe, eine Sprache aus Sätzen der Sprache zu identifizieren, der natürlichen Sprachlernaufgabe? Welche Faktoren des natürlichen Spracherwerbs erleichtern den Kindern die Aufgabe und kommen in der Formalisierung des Sprachidentifizierens nicht vor? Wie kann zum Beispiel die Pragmatik, das Handeln mithilfe von Sprache, in das formale Lernmodell einbezogen werden und wie komplex wäre dann dies Sprachlernen? Welche Annahmen über vorgegebene (angeborene) Sprachfähigkeiten müssen gemacht werden, um zu erklären, daß jedes gesunde Kind aus unvollständigen und oft sogar falschen Beispielen eine komplexe Sprache erlernt? Wie können solche Annahmen formalisiert werden? Kann dann gezeigt werden, daß die so formalisierte Lernaufgabe mit Vorgaben weniger komplex ist als das Identifizieren einer Sprache aus positiven Beispielen? Ein verwandtes Problem ist die anzunehmende Qualität der gelernten Sprache. Es wurde bewiesen, daß es ein NP-hartes Problem ist, den kürzesten mit gegebenen positiven und negativen Beispielen übereinstimmenden regulären Ausdruck zu finden. Wollen wir annehmen, daß die interne

Grammatik bei Menschen in optimaler Form vorliegt oder erleichtern sich Menschen das Sprachlernen dadurch, daß sie umständlichere "Regeln" als nötig erwerben? Wenn der Bezug zwischen menschlichem und maschinellern Lernen ernst genommen wird, eröffnet sich hier ein weites Feld für die Forschung.

Logikbasiertes Lernen für die Robotik

Erst in jüngerer Zeit sind die technischen Voraussetzungen geschaffen, um Sensordaten schnell zu verarbeiten. Es besteht jetzt die Herausforderung, automatisch aus Sensordaten höhere Ebenen der Repräsentation wie etwa Begriffe (wir wollen schließlich Intelligenz nicht auf Reflexe reduzieren!) zu erzeugen, so daß sich Begriffe auf Wahrnehmungen gründen. Da gerade für Anwendungen in der Robotik immer wieder behauptet wird, daß logikbasierte Ansätze ungeeignet wären, soll hier ein logikbasiertes Verfahren vorgestellt werden, das aus den Sensordaten eines Roboters Begriffe (etwa für das Bewegen durch eine Tür) lernt (Morik, Rieger 1993). Im Gegensatz zu auf neuronalen Netzwerken basierenden Verfahren, die zwar für die Hindernisvermeidung gute Lernergebnisse aufweisen (Millan, Torras 1992), aber keinen Bezug zu einer begrifflichen Ebene bieten, im Unterschied auch zu den Ansätzen von Rodney Brooks (Brooks 1991), deren verschiedenen Ebenen von Hand programmiert (oder gelötet) werden müssen, können hier die verschiedenen Ebenen zwischen Sensor- und Aktionsdaten und Begriffen im Zusammenhang behandelt werden. Damit wird ein Beitrag zum Verständnis des "symbol grounding" geleistet, das heißt dazu, wie Merkmale, die zur Definition eines Begriffs verwendet werden, in der sinnlichen Wahrnehmung verankert sind.

Die Lernaufgabe, der wir uns im Projekt BLearn-II stellen, ist nicht interdisziplinär, sondern von Anwendungen her motiviert. Die langen Umrüstzeiten für Roboter sollen reduziert werden. Bisher braucht ein Roboterfahrzeug eine genaue Karte seiner Umgebung, Definitionen der Objekte in der Karte sowie genaue Angaben von Ausgangs- und Zielpunkten oder manuelles Training, um sich dem Willen des Benutzers entsprechend zu bewegen. Wir wollen nun, daß der Benutzer Fahrplanweisungen in einer dem Benutzer gemäßen und von einer speziellen Umgebung unabhängigen Weise geben kann. So soll er zum Beispiel "Gehe durch die Tür und dann links bis zum Schrank, dann halte an." in einer höheren Sprache formulieren können, bei der die Anpassung an die tatsächlichen Koordinaten dem Roboter überlassen bleibt:

```
move_through_door (X, Start, E1, M1), turn_left (X, E1, E2, M2),
approach_cupboard (X, E2, End, M3), stop (X, End).
```

Großbuchstaben bezeichnen Variablen, wobei für X die Fahrt, für Start, E1, E2, End Zeitpunkte und für M1, M2, M3 Bewegungsarten für eine

bestimmte Fahrt eingesetzt werden. Vom Benutzer werden nur die Relationen angegeben: alle Anweisungen beziehen sich auf dieselbe Fahrt; der Zeitpunkt, an dem das Fahrzeug durch die Tür gegangen ist, ist derselbe, an dem das Fahrzeug nach links dreht, und der Zeitpunkt, an dem der Schrank erreicht wird, ist derselbe, an dem das Fahrzeug anhält; alle Anweisungen enthalten verschiedene Bewegungstypen.

Um solche Anweisungen in einer dem Roboter noch unbekanntem Umgebung ausführen zu können, müssen die Bewegungen mit den Sensordaten in der Weise koordiniert werden, daß zum Beispiel eine Tür oder ein Schrank erkannt werden.⁶ Wir kombinieren Handlungs- und Bewegungsmerkmale zu *operationalen Begriffen*. Die Tür oder der Schrank werden nicht als solche repräsentiert, sondern als Durch-die-Tür-Gehen, An-der-Tür-entlang-Gehen, als Auf-einen-Schrank-Zugehen oder Von-einem-Schrank-Weggehen. Die Sensor- und Handlungsmerkmale ergeben zusammen ein bestimmtes Muster, den operationalen Begriff. In dieser Weise ist Objekterkennung und Handeln mit dem Objekt (hier eine bestimmte Fahrt in Bezug auf das Objekt) nicht getrennt. Die Merkmale, die zur Begriffsdefinition verwendet werden, geben Muster von Sensordaten bei Bewegungstypen an. Die Muster betreffen auf der obersten Ebene ganze Sensorgruppen, auf der Ebene darunter von einzelnen Sensoren angemessene Folgen von Daten. Auf der untersten Ebene werden bestimmte Folgen von Meßwerten mit Abweichungen zu Basismerkmalen zusammengefaßt. Beispiele für Regeln auf den verschiedenen Ebenen sind:

```
r1:
sg_jump(X, right_side, T1, T2, parallel) &
sg_jump(X, left_side, T1, T3, parallel)
& Start ≤ T1 & T2 ≤ End -->
move_through_door (X, Start, End, parallel)
```

```
r2:
s_jump(X, Sensor1, T1, T2, parallel) &
s_jump(X, Sensor2, T3, T4, parallel) &
s_jump(X, Sensor3, T5, T6, parallel) & succ(T1, T3) & succ(T3, T5) &
sclass(X, Sensor1, Y, Z, right_side) &
sclass(X, Sensor2, Y, Z, right_side) &
sclass(X, Sensor3, Y, Z, right_side) &
Y ≤ T1 & T6 ≤ Z -->
sg_jump (X, right_side, T1, T6, parallel)
```

```
r3:
stable(X, Orientation, Sensor, T1, T2, Gradient1) &
incr_peak(X, Orientation, Sensor, T2, T3, Gradient2) &
stable(X, Orientation, Sensor, T3, T4, Gradient3) -->
s_jump(X, Sensor, T1, T4, parallel)
```

Dabei sind die Prädikate `incr_peak` und `stable` einige der Basismerkmale, die direkt aus Sensormessungen der Form

```
measure(X, Time, Sensor, MeasuredDistance, SensorOrientation,
        SensorPosition)7
```

berechnet werden. Wenn der gemessene Abstand zum nächsten Objekt bei einer Folge von Zeitpunkten in etwa gleich bleibt, gilt `stable` für dies Zeitintervall. Wenn eine plötzliche Zunahme des Abstandes festgestellt wird, gilt `incr_peak`. Mißt ein Sensor bei derselben Orientierung an aufeinander folgenden Zeitintervallen zunächst eine grade Strecke, dann eine größere Entfernung und darauf folgend wieder eine grade Strecke, so wird diese Muster `s_jump` genannt und bezieht sich auf das Zeitintervall beginnend beim ersten Zeitpunkt vom ersten `stable` und endend beim letzten Zeitpunkt vom zweiten `stable`.




Abb. 1: Roboter, dessen Sensor auf der rechten Seite das Muster `s_jump` mißt

Messen alle Sensoren einer Sensorklasse (`right_side`) des Roboters jeweils nacheinander (`succ`) Daten des Musters `s_jump`, so ist das abstraktere Muster `sg_jump` für eine Fahrt parallel zu den Objektkanten gegeben. Bei der parallelen Fahrt durch die Tür tritt dieses Muster auf beiden Seiten des Roboters gleichzeitig auf, bei der diagonalen Fahrt zeitlich versetzt.

Schon die manuelle Eingabe solcher operationaler Begriffe und abstrakterer Merkmale, die das Fahrzeug in seiner Fahrtplanung verwendet, würde das Umrüsten von Robotern auf neue Umgebungen und die Mensch-Roboter-Kommunikation erleichtern. Die Regeln lassen sich in beliebigen Umgebungen auswerten und können so Objekte erkennen oder zumindest angemessene Kantenkonfigurationen wiedergeben. Durch die eingeschränkte Prädikatenlogik können Relationen zwischen Zeitpunkten und die Beziehung zwischen Wahrnehmungsmerkmalen, Bewegungstypen relativ zu Objekten und Sensorgruppen elegant ausgedrückt werden. Wir wollen aber obendrein die Merkmale und Begriffe lernen lassen. Tatsächlich wurden die oben angegebenen Regeln von dem logikbasierten Lernverfahren RDT (Kietz, Wrobel 1992) und auch von dem Verfahren GRDT (Klingspor 1994) gelernt. Dazu wurden 28

Fahrtprotokolle von Fahrten durch und entlang einer Tür mit Abstandsmessungen durch 24 Schallsensoren eingegeben, bei denen zu jeder Messung die angemessene Kante angegeben wurde.⁸

```
measure (X, Time, Sensor, MeasuredDistance, SensorOrientation,
        Sensorposition, Object, Edge)
```

Die Eingabe in das Lernprogramm sind also klassifizierte Beispiele, hier: Fahrten in bekannter Umgebung. Abbildung 2 zeigt die Fahrten von PRIAMOS durch Pfeile an, die Kanten sind durchnummeriert. Bei einigen Fahrten stand rechts neben der Tür ein Schrank, bei anderen nicht (die Kantennummern des Schranks sind nicht angezeigt, um das Bild nicht zu verwirren).




Abb. 2: Fahrten durch eine bekannte Umgebung zum Erlernen des operationalen Begriffs der Tür

Aus den so gewonnenen 17472 Messungen wurden zunächst die Muster für einen Sensor gelernt (129 Regeln bzw. bei anderen Lernparametern 62 oder 48 Regeln), dann die Muster für Sensorgruppen (16 Regeln) und schließlich 3 (bei anderen Lernparametern 2) Regeln für `move_through_door`. Die aus Fahrten in einer bekannten Umgebung gelernten Regeln können nun für Fahrten in noch unbekanntem Umgebungen genutzt werden. Dabei kann es zu Fehlklassifikationen kommen. So war eine der ursprünglich 3 gelernten Regeln für `move_through_door` zu allgemein. Erst die Verschärfung der Lernparameter ergab die zwei Regeln, die dann korrekt klassifizierten. Es soll also nicht verschwiegen werden, daß Lernen ein fehlerbehafteter Prozeß ist und daß es durchaus einen Aufwand darstellt, das System zu lehren (Beispiele

bereitstellen, die richtigen Parameter finden). Weitere Experimente werden das Aufwand-Nutzen-Verhältnis unseres Ansatzes genauer fassen. Im Unterschied zu einem im selben Projekt erarbeiteten konnektionistischen Lernen bei der Pfadplanung muß aber nicht der genaue Start- und Zielpunkt für ein Fahrt vorgegeben werden, was ja bei einer Fahrt in bisher unbekannter Umgebung auch nicht möglich wäre. Ein weiterer Vorteil ist die einheitliche Darstellung verschiedener Ebenen von Merkmalen bzw. Begriffen, so daß der Zusammenhang der verschiedenen Ebenen expliziert wird und Repräsentationen aufeinander aufgebaut werden können. Das konnektionistische Modell verharrt auf einer reflex-nahen Ebene, die zur Hindernisvermeidung ausgezeichnet geeignet ist, es jedoch nicht erlaubt, für eine Ebene abstrakter Merkmale oder die begriffliche Ebene genutzt zu werden. Denselben Nachteil haben Felddarstellungen, die aufgrund von Sensordaten erstellt werden können.⁹ Es zeigt sich also, daß logikbasierte Verfahren auch in der Robotik für weitreichende Lernaufgaben einsetzbar sind.

Die Relevanz der physischen Ebene

Kommen wir noch einmal auf das Beispiel der Ameise zurück. In der Beschreibung von Simon ist ihr Verhalten sehr ähnlich dem von konnektionistischen Lernverfahren in der Pfadplanung. Simon sagte aber auch, daß die Zellstruktur der Ameise irrelevant für die Beschreibung ihres Verhaltens ist. Das neuronale Netzwerk des Systems muß nicht, ja soll nicht einmal den biologischen Neuronen der Ameise gleichen. Ähnlich argumentiert Wilks (1976), wenn er schreibt, daß die Handlung des Essens nicht adäquat durch die physischen Prozesse des Arms, der Zähne und Kiefer, der Speiseröhre und des Magens zu beschreiben sind. Nur in seltenen Kontexten (etwa beim Arzt) hilft diese Beschreibungsebene weiter. Hier besteht ein Unterschied zur Neuroinformatik, die teilweise physische Prozesse direkt als Modell intelligenten Verhaltens betrachtet. Eine Theorie (Beschreibung, Modell) intelligenten Verhaltens muß diejenigen technischen Terme verwenden, die in übersichtlicher und systematischer Weise Verhalten vorherzusagen erlauben. Auch wenn wir wissen, daß bei Mensch und Tier biochemische Prozesse zum Beispiel sprachliche Äußerungen realisieren, müssen diese Prozesse nicht zur Beschreibung von Sprache herangezogen werden. Können biochemische Prozesse natürliche Sprachen so angemessen beschreiben wie Grammatiken und semantische Kalküle es tun? Um vorherzusagen, daß der Satz "Ich benutze mich dessen" von Sprechern des Deutschen als falsch betrachtet wird, sind die Gehirnvorgänge, die diese Entscheidung ausführen, nicht zu berücksichtigen. Die Analyse, daß der Satz eine Vermischung von "Ich benutze das." und "Ich bediene mich dessen." darstellt, gründet sich vielmehr auf syntaktisch-lexikalisches Wissen, das unabhängig von seiner physischen Realisierung zu

betrachten ist. Wir tun also gut daran, zur Beschreibung intelligenten Verhaltens das Fachvokabular von Psychologie und Linguistik zu verwenden, das sich nicht auf Körpervorgänge stützt. "Ein Vertreter des Mentalismus ... benötigt keinerlei Annahmen über die mögliche physiologische Basis der mentalen Realität, die er untersucht." (Chomsky 1965:241)

Wir können aber natürlich Vorgänge des Gehirns in Bezug auf kognitive Leistungen als Forschungsgegenstand wählen. Aber selbst dann sind die in Linguistik und Psychologie erarbeiteten Theorien mit ihrem "nicht-physischen" Vokabular notwendig für die Beschreibung des produzierten Verhaltens, denn dieses Vokabular beschreibt auf abstrakte und funktionale Weise "eine physische Realität", wie es Helen Leuniger nennt. Sie weist stringent nach, daß phonologische, syntaktische und semantische Theorien auch für die Untersuchung des (sprachverarbeitenden Teils des) Gehirns notwendig sind. In ihrem Buch über das Sprachverhalten gehirngeschädigter Menschen untersucht sie die Fehlleistungen bei Broca-, Wernicke- und globaler Aphasie (Leuniger 1989). Sie beschreibt sprachliches Verhalten und dessen Störungen mithilfe linguistischer Termini und überprüft Modelle der Sprachverarbeitung wiederum an empirischen Daten über Äußerungen von Aphasikern. Die Argumentationsfigur ist dabei wie folgt:

- Nehmen wir eine bestimmte einzelsprachliche Struktur an, die wir in Ausdrücken einer generellen Sprachtheorie beschreiben. Ein Beispiel ist die Silbenstruktur des Deutschen, die einfache Silben aus Konsonant und Vokal (CV, etwa "do") bis hin zu komplizierten Silben der Form CCCVCCC (etwa in "Strumpf") umfaßt, nicht aber - wie das Tschechische - Silben der Form CCC. Ein anderes Beispiel ist die phonologische Struktur des Deutschen, die bestimmte Lautfolgen als möglich und eine Teilmenge davon als im Deutschen vorkommend erfaßt.
- Sprachliche Fehlleistungen von Aphasikern werden nun in Hinblick auf die verletzten Regelmäßigkeiten ihrer Muttersprache charakterisiert. Zum Beispiel wird festgestellt, daß Wernicke-Aphasiker die Gesetze der deutschen Silbenstruktur einhalten, Silben jedoch vereinfachen (etwa "Kombinakiven" statt "Kombination"). Je schwieriger gemäß der Silbenstruktur eine Silbe ist, desto anfälliger ist sie für Fehler. Oder es wird beobachtet, daß Broca-Aphasiker die phonologische Struktur des Deutschen auch bei ihren Fehlleistungen beachten (etwa "Kilder" - ein mögliches deutsches Wort - statt "Kinder" - das gemeinte richtige Wort).

- Indem die Fachterminologie hinreicht, um die Fehler von Gehirngeschädigten zu beschreiben, wird die Sprachtheorie auch in ihrer Erklärungskraft für physische Abläufe gestützt. Dieser Rückbezug geht bis hin zur Annahme bestimmter Sprachverarbeitungsmodule wie etwa das mentale Lexikon mit der Verbindung von Lautstruktur und Begriffsstruktur, das für Wörter der offenen Klasse (betonbare Inhaltswörter) einen anderen Zugriffsmechanismus zu verwenden scheint als für Wörter der geschlossenen Klasse (Wörter, die eine syntaktische Konstruktion markieren),¹⁰ da bei gesunden Sprechern die Reaktionszeiten bei der Worterkennung für die beiden Klassen verschieden sind. Einige Fehler von Broca-Aphasikern können als das Fehlen des speziellen Zugriffsmechanismus bei Wörtern der geschlossenen Klasse interpretiert werden.

Diejenigen Arbeiten der (sprachverarbeitenden) KI, die mit interdisziplinärer Zielsetzung entstanden sind, verfolgen einen ähnlichen Gedankengang,¹¹ wobei allerdings meist empirische Daten gesunder Sprecher benutzt werden und damit der Rückbezug auf eine Lokalisierung von Modulen im Gehirn entfällt. Ein enger Bezug zwischen den in der KI erarbeiteten Modellen etwa von begrifflichem Wissen oder von Abfolgen verschiedener Verarbeitungsmodule mit den entsprechenden Modellen, die Helen Leuniger (a.a.O.) anführt, lädt aber zur Nutzung von implementierten Modellen der KI (z.B. DeSmedt 90) auch für die Untersuchung von Sprachstörungen aufgrund von Gehirnverletzungen ein.

Beschreibungs- oder Konstruktionsansatz?

Wir kommen nun auf den vielleicht wichtigsten Unterschied zwischen dem Beschreibungsansatz der KI und dem Konstruktionsansatz vieler Neuroinformatiker: will man ein intelligentes Wesen (nach-)bauen oder will man intelligentes Verhalten beschreiben? Im ersten Fall soll auch der physische Prozeß künstlich nachgeahmt werden. Eine künstliche Ameise soll *konstruiert* werden. Dabei ist übrigens fraglich, ob man etwas dadurch versteht, daß man es nachbildet: das Artefakt kann leicht so undurchschaubar werden wie sein Urbild. Bei einem auf Erklärung gerichteten Forschungsinteresse ist daher genau zu prüfen, inwiefern die Konstruktion eines Artefaktes wirklich nützlich ist. Wenn ein "künstliches Wesen" konstruiert werden soll, damit es für bestimmte Anwendungen nützlich ist, wenn also kein Interesse an Erklärungen vorliegen muß, ist dennoch zu fragen, ob das System gut genug verstanden wird, um einen Einsatz zu rechtfertigen. Ich bezweifle, daß die Metapher des "Wesens" (being) für die Einschätzung eines künstlichen Systems geeignet ist. Bei neuronalen Netzwerken - um ein Beispiel zu nennen - hilft mathematisches Vokabular

jedenfalls weitaus mehr bei ihrer Charakterisierung als populär verkürzte Neuronenmodelle.

Im zweiten Falle geht es um die *Beschreibung* von Verhalten. Natürlich können nicht nur kognitive Prozesse beschrieben werden, sondern auch biochemische. Dabei sind die Beschreibungen der KI operational, d.h. sie produzieren das Verhalten, das sie beschreiben gemäß der Beschreibung. Dies erlaubt die Validierung der Beschreibung in eleganter Weise. Produziert ein natürlichsprachliches System eine falsche Äußerung, so ist etwas an der Beschreibung sprachlichen Verhaltens falsch. Gibt ein Regelsystem eine falsche Diagnose aus, so ist etwas an dem Sachbereichsmodell falsch. (Umgekehrt ist der Schluß natürlich nicht so einfach!) Der operationale Charakter von KI-Modellen hat manchmal zu Verwirrungen geführt. Die Metapher des etwas anderen Buches mag da helfen. Ein KI-Modell beschreibt etwas, wie es auch ein Buch tut. Eine Beschreibung - auch eine operationale - liegt auf einer anderen Ebene als das Verhalten selbst. Eine Entsprechung der physischen Ebene ist bei Beschriebenem und Beschreibung nicht nötig. Bei einem Buch verlangen wir niemals, daß sein Material dem des Beschriebenen ähneln soll. Ich glaube, daß es niemandem einfiel, Bücher deshalb als ungeeignet zu bezeichnen, weil sie mit nur 92 Zeichen in einer Farbe auf Papier etwas beschreiben, das vielfältig, vielfarbig ist und aus ganz anderen Materialien besteht. Mit Büchern (bzw. Schrift und Zahlen) haben die Beschreibungsformen der KI auch gemeinsam, daß sie selbstverständlich symbolisch sind. Eine Beschreibung ist immer symbolisch und die Eignung des Computers für Beschreibungen besteht darin, daß er eine symbolverarbeitende Maschine ist.¹² Dieselbe Klarheit, die wir inzwischen bezüglich der Schrift und der Zahlen in ihrer Abbildfunktion erreicht haben, können wir auch auf KI-Systeme anwenden. Es steht dann immer noch frei, ein bestimmtes Modell als unzureichend zu bezeichnen, weil es Aspekte nicht berücksichtigt, die für wichtig erachtet werden, oder weil es Faktoren aufnimmt, die als unwichtig angesehen werden, dies ist aber dann eine einzelwissenschaftliche Diskussion, nicht jedoch eine prinzipielle.

Die KI, in deren Geschichte der Konstruktionsansatz durchaus vertreten war, ist inzwischen auf dem Wege in die Normalität als Bereich der Informatik mit interdisziplinärem Bezug zu Psychologie und Linguistik (Brauer 1993). Die Ergebnisse der KI werden jetzt unspektakulär als ganz normale Software angewandt. KI-Systeme werden mit Bezug auf theoretische Fundierungen behandelt und nicht (mehr) in anthropomorphen Ausdrücken. Der Neuroinformatik wünsche ich einen entsprechenden Weg.

Danksagung

Insbesondere der Mitarbeiterin Anke Rieger und dem Mitarbeiter Volker Klingspor im Projekt BLearn II sowie den studentischen Hilfskräften des Projektes Stephanie Wessel und Stefan Sklorz sei an dieser Stelle für ihre Arbeit gedankt. Jörg-Uwe Kietz danke ich für aufschlußreiche Diskussionen über Einsatzmöglichkeiten von logikbasiertem Lernen und ermutigende Kommentare zu Vorversionen dieses Artikels. Dr. Jutta Fedrowitz, die die "NeuroWorlds" für das Wissenschaftszentrum Nordrhein-Westfalen so erfolgreich organisierte, gab den Anstoß für den Aufsatz.

Literatur

- Brauer 1993: KI auf dem Weg in die Normalität, *KI Sonderheft*, August 1993, 85 - 91.
- Brooks 1991: Intelligence without reason, *Procs. IJCAI-91*, Morgan Kaufmann, San Mateo, 569 - 595
- Busemann, Novak 1993: Generierung natürlicher Sprache, Görz(Hg.) *Einführung in die Künstliche Intelligenz*, Addison Wesley, Bonn, 499 - 558
- Chomsky 1965: *Aspects of the Theory of Syntax*, Cambridge, Massachusetts
- Clark, Niblett 1988: The CN2 Induction Algorithm, *Machine Learning Journal*, 3, 261 - 283
- DeSmedt 1990: *Incremental Sentence Generation*, Ph. D. thesis, Report 90-01, Katholieke Univ. Nijmegen
- Feigenbaum, Simon 1963: Elementary Perceiver and Memorizer - Review of Experiments, in: Hoggatt, Balderston (Hg.): *Symposium on Simulation Models - Methodology and Applications to the Behavioral Sciences*, Cincinnati
- Fisher, McKusick 1989: An Empirical Comparison of ID3 and Backpropagation, in: *Procs.IJCAI 89*, San Mateo, S. 788 -793
- Forgy 1982: RETE - A Fast Algorithm for the Many Pattern/Many Object Pattern Match Problem, in *Artificial Intelligence* 19, 17 -37.
- Kietz, Wrobel 1992: Controlling the Complexity of Learning Through Syntactic and Task-Oriented Models, Muggleton (Hg.) *Inductive Logic Programming*, Academic Press, London, 335 - 360
- Kietz 1993: Some Lower Bounds for the Computational Complexity of Inductive Logic Programming, Brazdil(Hg) *Machine Learning - ECML-93*, Springer, Berlin, 115 - 123
- Kietz, Dzeroski 1994: Inductive Logic Programming and Learnability, *SIGART Bulletin*, Januar 1994
- Klingspor 1994: GRDT: Enhancing Model-Based Learning for Its Application in Robot Navigation, Report 5, Univ. Dortmund, LS VIII
- Leuninger 1989: *Neurolinguistik - Probleme, Paradigmen, Perspektiven*, Westdeutscher Verlag, Opladen
- Mitchell 1985: LEAP - A Learning Apprentice for VLSI Design, *Procs. IJCAI-85*, Morgan Kaufmann, Los Altos

- Mc Culloch, Pitts 1943: A Logical Calculus of the Ideas Immanent in Neural Activity, *Bulletin Math. Biophysics*, 5, 115 - 133
- Millan, Torras 1992: A Reinforcement Connectionist Approach to Robot Path Finding in Non-Maze-Like Environments, *Machine Learning Journal*, 8, 363 - 395
- Millan, Morik, Rieger, Klingspor, Moneta, Kaiser 1993: *Workpackage 4 - Navigation*, Deliverable 402
- Minsky 1954: *Neural Nets and the Brain Model Problem*, Ph D thesis Princeton Univ.
- Minsky, Papert 1969: *Perceptrons*, expanded edition 1990, MIT Press, Cambridge
- Morik, Wrobel, Kietz, Emde 1993: *Knowledge Acquisition and Machine Learning - Theory, Methods, and Applications*, Academic Press, London
- Morik, Rieger 1993: Learning Action-oriented Perceptual Features for Robot Navigation, Report 3, Univ. Dortmund, LS VIII.
- Muggleton (Hg.)1992: *Inductive Logic Programming*, Academic Press, London
- Olshen, Breimann, Friedman, Stone 1984: *Classification and Regression Trees*, Wadsworth and Brooks, Monterey.
- Quinlan 1986: Induction of Decision Trees, *Machine Learning Journal*, 1, 81 - 106
- Quinlan 1987: Generating Production Rules from Decision Trees, *Procs. of IJCAI-87*, Morgan Kaufmann, Los Altos, 304 - 307
- Rosenblatt 1959: Two Theorems of Statistical Separability in the Perceptron, *Procs. Mechanisation of Thought Processes*, London.
- Rosenblatt 1962: *Principles of Neurodynamics*, Spartan Books, New York
- Simon 1969: *The Sciences of the Artificial*, Cambridge.
- Simon 1978: Acht Vorlesungen über kognitive Psychologie gehalten an der Universität Hamburg, Fachbereich Psychologie.
- Turing 1959: Computing Machinery and Intelligence, *Mind* 59, deutsch in: Dotzler, Kittler (Hg) *Alan Turing - Intelligence Service*, Berlin.
- Weiss, Kapouleas 1989: An Empirical Comparison of Pattern Recognition, Neural Nets and Machine Learning Classification Methods, *Procs. IJCAI-89*, Morgan Kaufmann, San Mateo, 781 - 787
- Weiss, Kulikowski 1991: *Computer Systems that Learn - Classification and Prediction Methods from Statistics, Neural Networks, Machine Learning and Expert Systems*, Morgan Kaufmann, San Mateo
- Wilks 1976: Sprachverstehende Systeme der Künstlichen Intelligenz - Überblick und Vergleich, in: Eisenberg (Hg) *Semantik und Künstliche Intelligenz - Beiträge zur automatischen Sprachverarbeitung* Bd. 2, Berlin, 180 - 233.
- Wrobel 1991: Towards a Model of Grounded Concept Formation, *Procs. IJCAI*, Morgan Kaufmann, Los Altos

¹ Zur Debatte des "symbol grounding" siehe (Wrobel 1991).

² Neuere Arbeiten zum Lernen von Entscheidungsbäumen haben eine größere Fehlertoleranz erbracht.

³ Zum logikbasierten Lernen bietet der von Stephen Muggleton herausgegebene Band *Inductive Logic Programming* einen hervorragenden Überblick (Muggleton 1992)

⁴ Eine ausführliche Darstellung des Systems MOBAL mit einigen Anwendungen ist (Morik et al. 1993).

⁵ Die Tagungsbände der Konferenzen *Computational Learning Theory* sowie *Inductive Logic Programming* oder *Analogical and Inductive Inference* enthalten reiches Material zur Lernbarkeit.

⁶ Natürlich sind auch noch andere Prozesse nötig, wie etwa das Suchen nach einer Tür oder das Eintragen von erkannten Objekten entlang des Weges um allein Vorgänge auf der abstrakten Ebene zu nennen.

⁷ Hier wie auch in der Angabe des klassifizierten `measure` Prädikates faßt `SensorPosition` der Übersichtlichkeit halber die x-, y-, z-Koordinaten der Sensorposition und die der Roboterposition zusammen.

⁸ Das Fahrzeug PRIAMOS der Universität Karlsruhe lieferte uns die Daten.

⁹ Auch dazu wird ein Ansatz im Projekt BLearn-II entwickelt. Einen Überblick über die verschiedenen im Projekt BLearn-II erarbeiteten Ansätze zu Lernen für die Navigation bietet (Millan et al. 1993).

¹⁰ Die Wörter der offenen Klasse werden gemäß ihrer Gebrauchshäufigkeit abgerufen, Wörter der geschlossenen Klasse sind frequenzunabhängig (Leuninger 1989: 139ff).

¹¹ Eine sehr schöne Darstellung über die anzunehmenden Prozesse bei der Sprachgenerierung bieten Busemann und Novak (1993). Der Beitrag kann exemplarisch als typisch für die Arbeitsweise und Argumentation in der KI gelesen werden.

¹² Natürlich sind auch Gleichungssysteme oder Berechnungen mit Zahlen symbolisch und nicht etwa "subsymbolisch" wie manchmal neuronale Netzwerke genannt werden. Der Gegensatz zwischen Logik und numerischen Verfahren

besteht nicht darin, daß das eine symbolisch, das andere "subsymbolisch" sei!
Beide Systeme der Symbolmanipulation sind gleichwertig, nur eben für
unterschiedliche Anwendungen geeignet.

