

Lernen qualitativer Merkmale aus numerischen Robotersensordaten

Diplomarbeit von
Stephanie Wessel

betreut von
Prof. Dr. Katharina Morik
und
Dr. Joachim Hertzberg

März 1995



Universität Dortmund
Fachbereich Informatik



Zusammenfassung

Diese Arbeit ist eingebunden in ein Forschungsprojekt, bei dem Maschinelles Lernen eingesetzt wird zur Definition operationaler Begriffe für die Anwendung in der Roboternavigation. Auf der untersten Ebene ergibt sich dabei ein *signal-to-symbol*-Problem.

Als Lösung wird hier ein Verfahren vorgestellt, das numerische Sensordaten eines mobilen Roboters inkrementell zu qualitativen Wahrnehmungsmerkmalen verarbeitet, die sowohl zum Lernen abstrakterer Wahrnehmungsmerkmale als auch für die Navigation des Roboters verwendet werden können. Die Granularität der Wahrnehmungsmerkmale wird dabei von einem Lernalgorithmus bestimmt. Eine Analyse der Tests mit dem Verfahren zeigt Probleme auf, die sich aus dem Ansatz des Forschungsprojektes ergeben. Bei der Entwicklung von Lösungsansätzen wird daher auch angeregt, den Ansatz zu verändern.

Das vorgestellte Verfahren ist außerdem anwendbar zur Analyse numerischer Daten - beispielsweise in Datenbanken - und zur Diskretisierung stetiger Attributwerte - etwa als Vorverarbeitung für ID3-ähnliche Verfahren.

Inhalt

1	Szenario.....	1
2	Verfahren zur Analyse numerischer Daten.....	5
2.1	Zusammenfassen von Daten	5
2.1.1	Numerische Verfahren	5
2.1.1.1	Interpolation.....	5
2.1.1.2	Approximation.....	6
2.1.2	Maschinelles Entdecken	8
2.1.2.1	BACON-ähnliche Verfahren.....	9
2.1.2.2	E*.....	13
2.1.2.3	Bewertung der Verfahren des Maschinellen Entdeckens.....	15
2.2	Einteilen des Datenraumes.....	17
2.3	Diskretisierung stetiger Variablen.....	20
2.4	Zusammenfassende Bewertung der vorgestellten Verfahren	22
3	Generierung von Basiswahrnehmungsmerkmalen aus Sensordaten.....	24
3.1	Repräsentation.....	26
3.1.1	Aufgaben der Datenhaltung	28
3.1.1.1	Algorithmus zur Vorverarbeitung der Sensordaten.....	30
3.2	Das Verfahren zur Generierung der Basiswahrnehmungsmerkmale	31
3.2.1	Definition der Merkmalssymbole.....	31
3.2.1.1	Merkmalssymbole für Normalfälle.....	32
3.2.1.2	Merkmalssymbole für Sonderfälle.....	37
3.2.2	Der Algorithmus.....	40
3.2.2.1	Fallunterscheidung für jeden Datensatz.....	41
	I Trace-Anfang.....	42
	II Trace-Ende.....	48
	III alle übrigen Fälle.....	51
3.2.2.2	Beeinflußbare Kriterien für das Beenden eines Zeitintervalls.....	72

3.3 Test und Analyse des Verfahrens zur Generierung der Basiswahrnehmungsmerkmale	86
3.3.1 Ziel der Tests	86
3.3.2 Testverfahren	88
3.3.2.1 Algorithmus zur Bewertung der generierten Sequenzen von Basiswahrnehmungsmerkmalen.....	88
3.3.2.2 Algorithmus zur Überprüfung der systematischen Intervalleinteilung.....	91
3.3.2.3 Testdaten	94
3.3.3 Testergebnisse	96
3.3.4 Analyse	102
3.3.5 Folgerungen für das Lernverfahren.....	107
4 Lernen eines geeigneten Parametersatzes für die Generierung der Basiswahrnehmungsmerkmale	109
4.1 Das Lernverfahren	109
4.2 Test und Analyse des Lernverfahrens.....	115
4.2.1 Ziel der Tests	115
4.2.2 Testverfahren	115
4.2.3 Testergebnisse	116
4.2.4 Analyse	121
5 Schlußbetrachtungen	126
Definitionen.....	131
Danksagung.....	132
Literatur.....	133

Hinweis

Die Seite 131 ist eine Doppelseite zum Ausklappen, was bei der Fülle der hier verwendeten erklärungsbedürftigen Begriffe von unschätzbarem Wert ist.

1 Szenario

Die vorliegende Arbeit ist eingebunden in das Forschungsprojekt B-Learn II¹, bei dem Methoden des Maschinellen Lernens in die Robotik in den Teilbereichen Handhabung und Navigation integriert werden. Das Ziel der Integration ist,

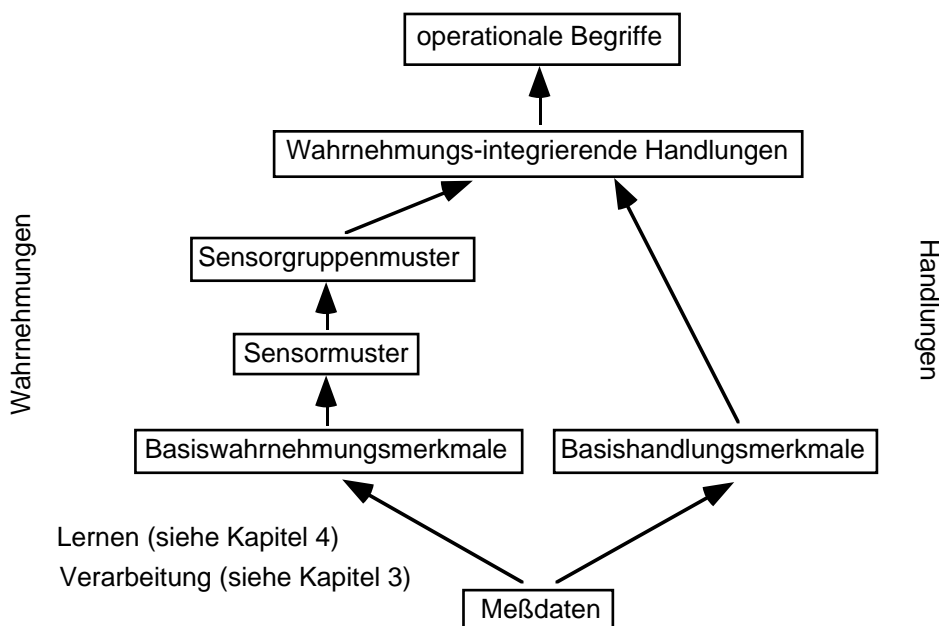
- die langen Einrichtungs- bzw. Umrüstzeiten bei Roboteranwendungen zu verkürzen

und

- die Bedienung von Robotern menschengerechter zu gestalten.

Die Forschungsaktivitäten am Lehrstuhl für Künstliche Intelligenz der Universität Dortmund beziehen sich auf das Gebiet der Navigation.

Zur Einordnung dieser Arbeit innerhalb der Navigation sei eine kurze Übersicht der Teilaufgaben vorangestellt. Das Ziel ist, Regeln für operationale Begriffe zu lernen, also beispielsweise für das Fahren durch eine Tür. Operationale Begriffe integrieren Wahrnehmungen und Handlungen des Roboters [Klingspor und Morik 1995].



Auf der Seite der Wahrnehmungen werden die Meßdaten schrittweise abstrahiert. Dabei ergibt sich auf unterster Ebene, also als erster Abstraktionsschritt, die Aufgabe, Meßdaten eines Roboters geeignet zu verarbeiten. Das Resultat dieses Verarbeitungsschrittes sind sogenannte Basiswahrnehmungsmerkmale. Eine genaue Definition dieses Begriffes folgt in Kapitel 3.1. Hier sei nur gesagt, daß es

¹ Förderung: ESPRIT P 7274, Land NRW

sich um einfache Merkmale handelt, mit denen mehrere aufeinanderfolgende Meßdaten zusammenfassend beschrieben werden.

Die Meßdaten stammen von einem mobilen Roboter, der sich durch einen Raum bewegt. Der Roboter, PRIAMOS [Dillmann et al. 1993], wurde an der Universität Karlsruhe entwickelt. Er kann sich in jede Richtung bewegen und gleichzeitig drehen. PRIAMOS ist mit 24 Ultraschallsensoren ausgestattet, die sich rund um den Roboter in gleicher Höhe befinden. Die Sensoren messen den Abstand zum nächstgelegenen Objekt innerhalb des Schallkegels.

Neben Ultraschallsensoren werden in der Robotik auch noch andere Systeme eingesetzt, die Daten über die Umgebung eines Roboters liefern. Eine Alternative ist beispielsweise die Installation einer Kamera auf einem Roboter. Diese Lösung würde die einzelnen Lernschritte auf der Seite der Wahrnehmungen überflüssig machen. Eine Kamera ist relativ kostengünstig und präzise. Ihr Einsatz erfordert aber einen sehr hohen Aufwand, bis Tausende von Bildpunkten soweit verarbeitet sind, daß sie als Eingabe für eine Planungskomponente dienen können. Eine weitere Möglichkeit besteht im Einsatz eines Lasers zur Distanzmessung. Die sehr hohe Meßgenauigkeit und die schnelle Verfügbarkeit des Meßergebnisses für die Weiterverarbeitung sprechen für diese Lösung. Die hohen Kosten sprechen allerdings dagegen. Letztendlich ist die Entscheidung für den Einsatz von Ultraschallsensoren im Projekt B-Learn II aufgrund des Abwägens zwischen den drei Faktoren

- Genauigkeit
 - Aufwand für die Weiterverarbeitung bis zur Eingabe für eine Planungskomponente
- und
- Kosten

getroffen worden. Ultraschallsensoren sind zwar ungenau, liefern aber sofort ein Meßergebnis, das dann schrittweise abstrahiert werden kann, und sind ausgesprochen kostengünstig.

Fehler bei Ultraschallmessungen können beispielsweise auftreten, wenn die abgestrahlten Schallwellen mehrfach reflektiert wurden, ehe sie den Sensor wieder erreichen. Die Ungenauigkeit der Messungen hat natürlich negative Konsequenzen für alle Verarbeitungs- und Lernschritte, die auf diesen Messungen aufbauen. Man muß sich von vornherein darüber im klaren sein, daß es nicht möglich ist, absolut verlässliche Merkmale zu bestimmen, mit denen man dann perfekte Regeln für die abstrakteren Begriffe lernen könnte.

Wie gesagt beschäftigt sich diese Arbeit nur mit der untersten Abstraktionsstufe auf der Seite der Wahrnehmungen. Zum Lernen der Regeln für abstraktere Wahrnehmungsmerkmale und der Verknüpfung von Wahrnehmungs- und Handlungsseite wird dann der modellbasierte, induktive Lernalgorithmus RDT [Kietz und Wrobel 1991] verwendet. RDT lernt Instantiierungen eines Regelschemas, wobei mit den allgemeinsten Regeln begonnen wird, die dann spezialisiert werden. Lernziel sind die generellsten Regeln, die die von der

Benutzerin vorgegebenen Bewertungskriterien erfüllen - und zwar so viele Regeln wie möglich².

Die Regeln für abstraktere Wahrnehmungsmerkmale werden jeweils aus den Wahrnehmungsmerkmalen der nächstniedrigeren Stufe gelernt. Beispielsweise wird gelernt, welche Folgen von Basiswahrnehmungsmerkmalen ein bestimmtes Sensormuster bilden. Klingspor und Morik [Klingspor und Morik 1995] nennen Beispiele für gelernte Regeln für jede Abstraktionsstufe. Alle Verarbeitungs- und Lernschritte finden in der sogenannten **Lernphase** statt. Die Regeln für operationale Konzepte, die im letzten Schritt dieser Phase gelernt worden sind, sollen dann natürlich auch angewendet werden. In der sogenannten **Anwendungsphase** müssen wieder die gleichen Abstraktionsschritte durchlaufen werden: Zunächst werden die Meßdaten zu Basiswahrnehmungsmerkmalen verarbeitet. Für diese wird versucht eine Regel für Sensormuster anzuwenden. Als nächstes wird eine passende Regel für die so ermittelten Sensormuster bestimmt usw., bis schließlich eine Regel für einen operationalen Begriff angewendet werden kann.

Bei der Verarbeitung der Meßdaten sollen nur noch die für die Navigation benötigten Informationen erhalten bleiben. Als für die Navigation notwendig wird eine Reihe einfacher qualitativer Merkmale inklusive ihrer Definition vorgegeben, beispielsweise „ansteigend“ oder „gleichbleibend“, die sich auf die gemessenen Distanzen beziehen. Es soll also weder gelernt werden, wie ein vorgegebener Begriff (die Bezeichnung für ein Merkmal) zu definieren ist, noch sollen selbständig neue Begriffe gebildet werden.

Aus dem dargestellten Szenario ergibt sich folgende Präzisierung der Aufgabenstellung:

gegeben: 1) eine Folge numerischer Meßdaten
2) eine Menge qualitativer Merkmale

gesucht: eine Folge von Zeitintervallen,
denen jeweils ein passendes Merkmal zugeordnet ist

Da hier eine Abbildung quantitativer Daten auf qualitative Merkmale gefordert ist, handelt es sich um ein *signal-to-symbol*-Problem.

An ein Verfahren, das diese Aufgabe bewältigt, werden zusätzliche Bedingungen gestellt:

- Die Meßdaten sind nur in der Lernphase mit einer Klassifikation versehen. Da das Verfahren jedoch sowohl in der Lernphase wie auch in der Anwendungsphase angewendet werden muß, kann die Klassifikation nicht benutzt werden. Es kann also kein Verfahren angewendet werden, das aus Beispielen lernt. Als Eingaben für das Verfahren stehen lediglich

² Angewendet wird außerdem auch RDT/DB und GRDT [Klingspor 1994].

Beobachtungen in Form von Meßdaten zur Verfügung, die ein mobiler Roboter bei einer Fahrt durch einen Raum liefert.

- Ein Raum besteht im vorgegebenen Szenario aus verschiedenen Objekten: Wänden, Türen und Schränken. Auf seiner Fahrt durch den Raum erfaßt der Roboter verschiedene Objekte. Das Verfahren muß die Voraussetzungen dafür schaffen, daß die einzelnen Objekte unterscheidbar sind.
- Um die gesuchte Folge von Zeitintervallen zu bestimmen, müssen aufeinanderfolgende Meßdaten zunächst zusammengefaßt werden. Das Verfahren hat also die zeitliche Abfolge der Meßdaten zu berücksichtigen.
- In der Anwendungsphase muß der Roboter sofort auf Wahrnehmungen reagieren können. Die Voraussetzung dafür ist, daß das Verfahren die aktuellen Meßdaten auch sofort, d. h. inkrementell verarbeitet.

Für ein Zusammenfassen numerischer Daten gibt es bereits verschiedene Methoden. Es ist zunächst zu analysieren, ob eine dieser Methoden für die Aufgabenstellung geeignet ist. Falls das nicht der Fall ist, muß ein geeignetes neues Verfahren entwickelt werden.

In diesem Kapitel wurde die Aufgabenstellung der vorliegenden Diplomarbeit im Rahmen des Forschungsprojektes B-Learn-II dargestellt. Kapitel 2 beschäftigt sich mit verschiedenen Verfahren zur Analyse numerischer Daten im Hinblick auf die Bedingungen, die bei der Aufgabenstellung formuliert wurden. In Kapitel 3 wird ein neues Verfahren vorgestellt. Bei diesem Verfahren gibt es mehrere Varianten, die sich durch die Vorgabe bestimmter Parameter unterscheiden. Ein Teil dieser Parameter bestimmt die grundlegende Strategie bei der Verarbeitung, ein anderer Teil legt die Einzelheiten fest. Es wird zunächst analysiert, welche grundlegende Strategie am besten geeignet ist, die Meßdaten zusammenzufassen. Da die Qualität der generierten Basiswahrnehmungsmerkmale entscheidenden Einfluß auf das Lernen operationaler Begriffe hat (siehe [Wrobel 1991]), ist eine geeignete Wahl der Parameter von großer Bedeutung. Für diese Aufgabe wird in Kapitel 4 ein Lernverfahren präsentiert. Schließlich faßt Kapitel 5 die wichtigsten Aspekte dieser Diplomarbeit noch einmal zusammen, wobei auch Einsatzmöglichkeiten außerhalb des hier beschriebenen Szenarios genannt werden.

2 Verfahren zur Analyse numerischer Daten

Dieses Kapitel soll einen Überblick geben über Verfahren der Statistik und der Künstlichen Intelligenz, die sich mit der Analyse von Daten befassen mit dem Ziel, Daten geeignet zusammenzufassen. Es liegt nahe, unter der großen Zahl solcher Ansätze ein Verfahren zu vermuten, das bei der Lösung der in Kapitel 1 dargestellten Aufgabe helfen könnte.

2.1 Zusammenfassen von Daten


2.1.1 Numerische Verfahren

Die meisten statistischen Verfahren zur Datenanalyse gehen davon aus, daß das zu analysierende Phänomen homogen ist, d.h. daß die gesuchte Beziehung zwischen den Variablen bei allen Daten die gleiche ist [Breiman et al. 1984]. Diese Annahme liegt auch bei der klassischen Interpolation und Approximation vorgegebener Punkte zugrunde³. Die beiden Verfahren werden im folgenden ansatzweise vorgestellt. Ausführliche Darstellungen, wie man aus dem Ansatz ein Gleichungssystem erhält und wie es gelöst wird, finden sich in [Bronstein et al. 1987].

2.1.1.1 Interpolation

Ziel der Interpolation ist, eine Funktion zu finden, deren Graph genau durch die vorgegebenen Punkte läuft.

³ Hier handelt es sich um numerische Verfahren, die in der Statistik zum Einsatz kommen.



Präziser formuliert: Vorgegeben sind $n+1$ paarweise verschiedene Punkte $P_\mu = (x_\mu, y_\mu)$, $\mu \in \{0, \dots, n\}$, zu denen eine ganzrationale Funktion p_n höchstens n -ten Grades gesucht wird, die an den Stellen x_μ , die man als **Stützstellen** bezeichnet, gerade die Werte y_μ , die **Stützwerte**, annimmt.

Mit dem Ansatz, daß die Koeffizienten a_v des Polynoms $p_n(x) = \sum_{v=0}^n a_v x^v$

derart zu bestimmen sind, daß $\forall \mu \in \{0, \dots, n\}$ gilt $\sum_{v=0}^n a_v x_\mu^v = y_\mu$, erhält man ein Gleichungssystem, das eindeutig lösbar ist.

Bekannt sind außerdem Verfahren, bei denen ein etwas anderer Ansatz zu einem einfacheren Lösungsverfahren führt (siehe [Bronstein et al. 1987]).

Von Bedeutung ist außerdem die **Spline-Interpolation**. Dabei wird nicht nur eine ganzrationale Funktion bestimmt, sondern es wird jeweils eine ganzrationale Funktion p_μ höchstens k -ten Grades für $[x_\mu; x_{\mu+1}]$ berechnet für alle $\mu \in \{0, \dots, n-1\}$, also jeweils für das Intervall von einer Stützstelle zur nächsten. Auch hier wird natürlich gefordert, daß $p_\mu(x_\mu) = y_\mu$ und $p_{\mu+1}(x_{\mu+1}) = y_{\mu+1}$ für alle $\mu \in \{0, \dots, n-1\}$, also die Funktionen jeweils an den beiden zugehörigen Stützstellen gerade den Stützwert annehmen. Die einzelnen Funktionen p_μ werden zusammengesetzt zu einer Funktion S_n , für die zusätzlich gefordert wird, daß die 1. Ableitung von S_n , S_n' , auch in den Stützstellen stetig ist. Man erhält also eine „glatte“ Kurve⁴. Aus der geforderten Stetigkeit der 1. Ableitung resultieren die Bedingungen $p'_\mu(x_{\mu+1}) = p'_{\mu+1}(x_{\mu+1})$ für alle $\mu \in \{0, \dots, n-1\}$. Mit ihnen und Bedingungen für höhere Ableitungen und für

4 Diese spezielle Anordnung von Polynomen minimiert die Gesamtkrümmung der interpolierenden Kurve. Legt man ein elastisches Lineal (engl. *spline*) durch die vorgegebenen Punkte (Stützstelle; Stützwert), wird diese Eigenschaft ebenfalls annähernd erreicht. Die Spline-Interpolation präzisiert also mathematisch, was ein einfaches mechanisches Zeichengerät zur Konstruktion glatter Kurven annähernd leistet, und wurde auch nach ihm benannt.

die Randpolynome p_0 und p_{n-1} läßt sich ein eindeutig lösbares Gleichungssystem aufstellen.

2.1.1.2 Approximation

Im Gegensatz zur Interpolation geht es hier nicht darum, eine Funktion zu finden, deren Graph genau durch die vorgegebenen Punkte läuft, sondern es wird versucht eine Funktion oder einzelne Punkte anzunähern.

Die **Approximationstheorie** beschäftigt sich mit der Approximation von Funktionen in Intervallen. Dabei soll eine Funktion $f: [a;b] \rightarrow \mathbb{R}$ ⁵ durch eine Funktion p aus einer speziellen Funktionenmenge - i. a. aus der Menge der ganzrationalen Funktionen - soweit angenähert werden, daß $\forall x \in [a;b]$ und eine vorgegebene positive reelle Zahl ε gilt:

$$| f(x) - p(x) | < \varepsilon \quad 6$$

Von Interesse ist bei der Verarbeitung der Sensormeßdaten jedoch nicht die Annäherung einer Funktion, denn es ist keine Funktionsgleichung gegeben. Vielmehr geht es um die Annäherung von Meßpunkten. Eine der Approximation von Funktionen ähnliche Aufgabe besteht nun darin, eine endliche Menge von Meßpunkten in einem kartesischen Koordinatensystem durch den Graphen einer Funktion f möglichst gut anzunähern. Diese Funktion soll eine Linearkombination von m linear unabhängigen Funktionen g_v sein⁷:

$$f = \sum_{v=1}^m a_v g_v, \quad \text{mit } a_v \text{ aus der Menge der reellen Zahlen}$$

Im einfachsten Fall ($m = 1$ oder $m = 2$) wird also eine lineare Funktion gesucht, nämlich


$f(x) = a_1$ oder $f(x) = a_1 + a_2x$. In der Statistik wird dieses Verfahren häufig angewendet, um einen vermuteten Zusammenhang zwischen zwei Meßgrößen - etwa Körpergröße und Körpergewicht - mathematisch zu fassen. Man spricht bei diesem einfachsten Fall von **linearer Regression**. Der Graph einer solchen Funktion heißt **Regressions-gerade**.

5 Mit \mathbb{R} ist die Menge der reellen Zahlen gemeint.

6 Bei der Approximation ist die Funktion f die Eingabe, und ausgegeben wird die Funktion p .

Die Betragstriche sorgen dafür, daß es unerheblich ist, ob ein Funktionswert $p(x)$ größer oder kleiner ist als $f(x)$.

7 Die linear unabhängigen Funktionen g_v sind üblicherweise die Funktionen $g_v(x) = x^v$. Eine Linearkombination dieser Terme ergibt ein Polynom m -ten Grades.



Beispiel für eine Regressionsgerade

Der Funktionsterm, bei dem die Koeffizienten noch nicht festliegen, wird im folgenden als **Funktionsmodell** bezeichnet. Zur Festlegung der Funktion müssen die Koeffizienten a_v bestimmt werden. Um die $n+1$ Meßpunkte möglichst gut anzunähern, fordert man für die Koeffizienten z.B., daß

$$(1) \quad \sqrt{\sum_{\mu=0}^n \left(\sum_{v=1}^m a_v g_v(x_\mu) - y_\mu \right)^2}$$

minimal wird. Man möchte also erreichen, daß die Summe der absoluten Differenzen zwischen dem tatsächlichen Funktionswert y_μ und dem Wert der Funktion $\sum_{v=1}^m a_v g_v(x_\mu)$ möglichst klein ist. Häufig wird auf die Berechnung der

Wurzel verzichtet, oder es wird eine mittlere absolute Differenz berechnet:

$$(2) \quad \frac{1}{n+1} \sum_{\mu=0}^n \left(\sum_{v=1}^m a_v g_v(x_\mu) - y_\mu \right)^2$$

Wegen der Minimierung einer Quadratsumme heißt dieses Verfahren auch **Methode der kleinsten Quadrate**.

Auch mit Splines (siehe Kapitel 2.1.1.1) kann man die Meßpunkte (x_μ, y_μ) , $\mu \in \{0, \dots, n\}$, approximieren. Dabei werden Bedingungen für die Krümmung der Kurve und für die Anpassung an die Stützwerte aufgestellt. Eine Gleichung, die diese beiden Bedingungen verbindet, ermöglicht es, einen Kompromiß zu finden zwischen möglichst gleichmäßiger Krümmung und möglichst guter Anpassung an die Stützwerte. Wie bei der Interpolation ist auch hier wieder ein lineares Gleichungssystem zu lösen.

2.1.2 Maschinelles Entdecken

Für die Datenanalyse werden traditionell statistische und numerische Verfahren angewendet. Diese Verfahren manipulieren Zahlen, Gleichungen usw., ohne jedoch Hintergrundwissen oder Heuristiken zur Kontrolle des Prozesses einzubeziehen [Falkenhainer et al. 1986]. Ein statistisches oder numerisches Verfahren kann daher nur sinnvolle Ergebnisse liefern, wenn die Zahlen bereits in gewisser Weise vorverarbeitet worden sind. So sollte z.B. niemals ein statistisches Verfahren angewendet werden, ohne zu berücksichtigen, welches Meßniveau⁸ die Daten haben und aus welcher Grundgesamtheit sie erhoben wurden. Es können immer nur Teilaufgaben - etwa Interpolation oder Regression - mit einem traditionellen Verfahren gelöst werden. Zwischenschritte wie die Entscheidung, wie ausgehend von Teilergebnissen die Analyse fortgesetzt wird, liegen in der Hand der Person, die die Analyse der Daten durchführt [Zytkow et al. 1990]. Um die benötigte Datenvorbereitung und die Entscheidungen nach Zwischenergebnissen seitens einer Expertin zu reduzieren, wurden Verfahren zum maschinellen Entdecken numerischer Regularitäten entwickelt.

Maschinelles Entdecken umfaßt die Teilbereiche empirisches Entdecken und Theoriebildung. Während empirisches Entdecken zum Ziel hat, Daten zusammenzufassen in einer Art Gesetz, beschäftigt sich die Theoriebildung mit der Erklärung dieser Daten [Nordhausen und Langley 1993].

Empirisches Entdecken gliedert sich wiederum in drei Teilbereiche auf:

- Entdecken von Begriffshierarchien
- Entdecken qualitativer Zusammenhänge
- Entdecken quantitativer, also numerischer Zusammenhänge

Für die Verarbeitung von Meßdaten ist das Entdecken qualitativer Merkmale in numerischen Werten nötig. Da hierzu zunächst numerische Zusammenhänge aufgespürt werden müssen, beschäftigt sich dieses Kapitel nur mit dem letztgenannten Teilbereich des empirischen Entdeckens.

Maschinelles Entdecken läßt sich vage abgrenzen gegen den Teilbereich des Maschinellen Lernens, bei dem es um den Erwerb von Begriffen, Taxonomien oder Regularitäten geht: Lernen hängt von einer Tutorin oder einer anderen Wissensquelle ab, die an verschiedenen Stellen in den Lernprozeß eingreift. Von einer Entdeckung kann man dagegen nur sprechen, wenn sie ohne die Hilfe jemandes gemacht wurde, der das Entdeckte bereits vorher kannte [Zytkow 1993]. Die Übergänge sind fließend: Maschinelles Entdecken wird von Forscherinnen häufig als eine Form des Lernens aus Beobachtungen angesehen [Langley und Michalski 1986]. Conceptual clustering gehört z.B. sowohl zum Entdecken von Begriffshierarchien [Nordhausen und Langley 1993] als auch zum Lernen aus Beobachtungen.

8 D.h. man muß berücksichtigen, ob es sich bei den Merkmalsausprägungen um Begriffe, numerische Werte oder Mischformen handelt. Beispiel für eine Mischform ist das Merkmal „Schulnote“: Die Merkmalsausprägungen können sowohl Begriffe wie auch numerische Werte sein.

Allen Verfahren zum Entdecken quantitativer Zusammenhänge sind folgende Charakteristika gemein:

- Eingetragen werden Datensätze mit einer bestimmten Anzahl von Variablen. Üblicherweise handelt es sich um zusammengehörende Meßwerte verschiedener Größen, etwa Gasdruck, Temperatur usw..
- Das Verfahren sucht eine oder mehrere Funktionen, die die Daten beschreiben. Dabei sind drei Aufgaben zu bewältigen [Kokar 1986]:
 - Auswahl der relevanten Merkmale (Variablen) der Daten
 - Auswahl eines Funktionsmodells
 - Bestimmen der Koeffizienten des Funktionsmodells
- Ausgegeben wird eine Funktion, mehrere Funktionen oder „keine Beziehung“

2.1.2.1 BACON-ähnliche Verfahren

Alle Verfahren, die in diesem Kapitel vorgestellt werden, betrachten Entdecken als Suche in einem geordneten Raum von Funktionsmodellen, die möglicherweise die Eingabedaten erklären können. Zur Auswahl eines Funktionsmodells verwenden sie geeignete Heuristiken. Geeignet bedeutet hier, daß anzunehmen ist, daß sich die Eingabedaten mit diesem Modell gut beschreiben lassen. Um die Koeffizienten eines Funktionsmodells zu bestimmen, greifen sie auf die Regression zurück.

Alle Heuristiken gehen auf die Methode zurück, die in der ersten Version von BACON vorgestellt wurde. BACON [Langley et al. 1983] versucht monotone Beziehungen zwischen zwei Variablen zu finden. Wenn beispielsweise die Werte von y ansteigen bei ebenfalls ansteigenden Werten für x , liegt eine positive Abhängigkeit vor. Die übrigen Variablen müssen konstant bleiben. Ausgenommen sind davon Variablen, die kombiniert wurden aus einfacheren Variablen mit Beteiligung von x oder y , denn sie können bei Veränderung von x und y nicht konstant bleiben. Bei mehr als zwei Variablen in den Eingabedaten werden alle möglichen Kombinationen getestet. Wenn eine solche Beziehung zwischen zwei Variablen gefunden wird, wird eine neue Variable durch Linearkombination der alten Variablen oder als Produkt oder Quotient der alten Variablen eingeführt. Für neue Variablen wird ebenfalls wieder nach monotonen Abhängigkeiten gesucht. Dieses Verfahren wird wiederholt, so daß immer komplexere Variablen entstehen.

Bei der Auswahl eines Funktionsmodells verwendet auch Zembowicz und Zytkows **Equation Finder** [Zembowicz und Zytkow 1992] das Prinzip, aus einfachen Variablen komplexere zu bilden. Zembowicz und Zytkow argumentieren jedoch, daß die Klasse der polynomiellen Modelle, die z.B. von BACON und ABACUS [Falkenhainer et al. 1986] verwendet werden, für viele Anwendungen nicht ausreicht. Also werden neben Quotient, Produkt und Linearkombination einfacher Variablen auch noch Logarithmus, Exponent und Wurzel als mathematische Transformationen zur Bildung neuer Variablen herangezogen. Jede neue Variable wird vereinfacht und mit allen bisherigen verglichen, um sicherzustellen, daß es

sich tatsächlich um eine neue Variable handelt. Für jede mögliche Kombination der neuen Variablen und für jedes Polynom bis zum vorgegebenen Grad werden wieder die Koeffizienten durch Regression bestimmt.

Bezüglich der Eingaben nimmt EF eine Sonderstellung ein. Das Verfahren berücksichtigt den Fehler, mit dem jeder Meßwert behaftet ist. Ein Datensatz hat die Form $(x_\mu, y_\mu, \sigma_\mu)$, wobei x_μ die unabhängige Variable ist, y_μ die abhängige und σ_μ den Fehler⁹ von y_μ bezeichnet. EF wendet systematisch die *error propagation*-Theorie an, indem für jede Variable und für jeden Koeffizienten jedes Funktionsmodells ein Fehler berechnet wird. Die Fehler der Eingabedaten werden außerdem berücksichtigt bei der Berechnung der Koeffizienten für ein Funktionsmodell. Verwendet wird die Methode der kleinsten Quadrate (siehe Kapitel 2.1.1.2, Gleichung (1)), wobei aber die Differenz zwischen dem

tatsächlichen Funktionswert y_μ und dem Wert der Funktion $\sum_{v=1}^m a_v g_v(x_\mu)$ dividiert

wird durch den Fehler σ_μ :

$$(3) \quad \sum_{\mu=0}^n \left(\frac{\sum_{v=1}^m a_v g_v(x_\mu) - y_\mu}{\sigma_\mu} \right)^2$$

Diese Summe soll minimiert werden. Je größer also der Fehler eines Datensatzes ist, umso geringeren Einfluß hat die absolute Differenz, die für diesen Datensatz berechnet wird. Dieses Verfahren ist bekannt unter der Bezeichnung *weighted least-squares* [Eadie et al. 1971].

Die Funktionen, die man durch Kombination neuer Variablen erhält, werden bewertet durch einen Wert für die Wahrscheinlichkeit, daß der mit Gleichung (3) berechnete Wert nicht durch Zufall erreicht wurde. Wenn dieser Wert eine vorgegebene Grenze unterschreitet, wird die Funktion abgelehnt. Die Erweiterung des Suchraumes wird fortgesetzt, bis eine Funktion gefunden wird, deren Wert für diese Wahrscheinlichkeit eine vorgegebene Grenze überschreitet. Weitere Abbruchkriterien sind das Erreichen der maximalen Transformations-Suchtiefe oder des maximalen Polynomgrades. Alle diese Werte werden von der Benutzerin definiert. Vorgegeben werden kann außerdem, welche Transformationen ausprobiert werden sollen. Der Suchraum kann bei diesem Verfahren sehr groß werden.

Der bereits erwähnte Koeffizientenfehler wird benutzt, um überflüssige Terme in den Funktionsgleichungen zu eliminieren. Die Berechnung des Fehlers $\sigma_{a_v}^2$ für die Koeffizienten a_v , die mit dem Verfahren *weighted least-squares* bestimmt wurden, erfolgt gemäß der Formel für *error propagation* [Eadie et al. 1971]:

9 Man spricht auch von Unsicherheit, in der KI von verrauschten Daten und in der Statistik von Streuung.

$$\sigma^2_{a_v} = \sum_{\mu=0}^n \left(\frac{d a_v}{d y_{\mu}} \right)^2$$

Die Ableitung $\frac{d a_v}{d y_{\mu}}$ kann berechnet werden, da die Koeffizienten a_v Lösungen von Gleichungen sind (vgl. mit Kapitel 2.1.1.2), also Funktionen abhängig von x_{μ} , y_{μ} und σ_{μ} . Wenn dieser Fehler größer ist als der Absolutwert des Koeffizienten a_v , wird a_v auf 0 gesetzt, und der Term $a_v g_v(x_{\mu})$ verschwindet aus der Funktionsgleichung.

Auf die Darstellung weiterer Formeln wird hier verzichtet. Es sollte lediglich deutlich werden, daß EF zurückgreift auf bereits bekannte numerische oder statistische Verfahren. Diese Verfahren erfordern im Vergleich zu dem Verfahren, das in Kapitel 3 vorgestellt wird, relativ komplexe Berechnungen. In erster Linie steht jedoch ein anderes Problem der Verwendung der Verfahren, die von EF benutzt werden, im Weg. Eine Berücksichtigung von Meßfehlern ist sicherlich sinnvoll, aber bei den hier zu verarbeitenden Ultraschallmeßdaten nicht möglich, da die Angabe eines Fehlers zu jedem Meßwert nicht verfügbar ist.

Andere Verfahren zum Entdecken numerischer Regularitäten berücksichtigen Fehler nicht so konsequent wie EF. BACON, ABACUS und IDS [Nordhausen und Langley 1993] berücksichtigen z.B. nur einen konstanten Systemfehler.

Die meisten BACON-ähnlichen Systeme suchen nur nach einer einzigen Gleichung, mit der man alle Eingabedaten beschreiben kann. Es wird also ein homogener Datenraum vorausgesetzt, d.h. das Verhältnis der Variablen zueinander wird als stets gleich angesehen. Implizit wird bei allen hier vorgestellten Systemen von dieser Voraussetzung ausgegangen - auch bei den beiden Verfahren, die die Möglichkeit bieten, den Datenraum einzuteilen. Die AutorInnen der Artikel, in denen die hier vorgestellten Systeme beschrieben werden, beschäftigen sich überhaupt nicht mit diesem Aspekt. Die Begründung dafür dürfte sein, daß alle diese Verfahren darauf ausgerichtet sind, grundlegende physikalische oder chemische Gesetzmäßigkeiten zu entdecken. Von solchen Gesetzmäßigkeiten wird erwartet, daß eine einzige Formel ausreicht, um den Zusammenhang diverser Meßgrößen zu beschreiben.

Die beiden Verfahren, bei denen die Einteilung des Datenraumes möglich ist, sind ABACUS und ARC.2 [Moulet 1994]. Die Methode zum Entdecken quantitativer Regularitäten besteht bei diesen Verfahren aus zwei Schritten:

Im ersten Schritt wird versucht, eine Gleichung für alle Daten aufzustellen. Im Prinzip wird dabei die gleiche Methode angewendet wie bei BACON. Es werden jedoch nur solche neu gebildeten Variablen weiter verwendet, von denen anzunehmen ist, daß mit ihnen ebenfalls eine monotone Abhängigkeit gefunden werden kann. Welche der neuen Variablen die größte Aussicht auf Erfolg haben, wird durch eine Bewertungsfunktion überprüft. Es wird solange eine weitere Kombination zweier Variablen betrachtet, bis ein vorgegebener Prozentsatz

überschritten wird, der angibt, wieviel Prozent der Eingabedaten für eine bestimmte Variablenkombination den gleichen Wert annehmen muß. Werden von einer Gleichung nicht alle Eingabedaten erfaßt, wird aus allen Daten, auf die die Gleichung zutrifft, eine Teilmenge der Eingabedaten gebildet. Für die Daten dieser Teilmenge ist der erste Schritt bereits abgeschlossen. Für die restlichen Daten wird der erste Schritt erneut durchgeführt. Das Verfahren stoppt, wenn alle Eingabedaten einer Teilmenge zugeordnet wurden, die mit einer Gleichung versehen ist bzw. für die keine Gleichung aufgestellt werden konnte.

Im zweiten Schritt wird eine Bedingung für die Anwendbarkeit jeder Gleichung bestimmt.

Die Eingabedaten für Verfahren zum Entdecken numerischer Regularitäten werden durch mehrere Messungen im Verlauf verschiedener Experimente gewonnen. In diesem Fall ist es sicherlich sinnvoll, aus den Daten, die mit den gefundenen Funktionen nicht abzudecken sind, eine gesonderte Teilmenge zu bilden. Die Benutzerin könnte für diese Daten überprüfen, ob ein außergewöhnlich großer Meßfehler für diese abweichenden Daten verantwortlich ist, indem die betreffenden Messungen - ggfs. mehrmals - wiederholt werden. Das in Kapitel 1 vorgestellte Szenario erlaubt dieses Vorgehen jedoch nicht. Liefert der Roboter Meßdaten, die in bestimmter Weise aus dem Rahmen fallen, dürfen sie nicht einfach als nicht interpretierbare Daten von der Verarbeitung ausgeschlossen werden. Die Wiederholung „außergewöhnlicher“ Meßdaten wäre zwar möglich, indem der Roboter wieder ein Stück zurückfährt, um dann die gleichen Messungen nochmals durchzuführen. Angestrebt wird jedoch ein Verfahren, bei dem stets alle Meßdaten angemessen berücksichtigt werden, ohne daß der Roboter mehrfach hin- und herfahren muß. Auf das Problem „außergewöhnlicher“ Meßdaten geht Kapitel 2.1.2.3 näher ein.

Die einzelnen BACON-ähnlichen Verfahren unterscheiden sich noch in weiteren Punkten, die für das hier zu lösende Problem jedoch nicht relevant sind. Beispielsweise wird das Experimentdesign von einzelnen Systemen in unterschiedlichem Ausmaß selbständig durchgeführt. Experimente sind nötig, wenn für die zunächst eingegebenen Daten keine passende Gleichung gefunden werden konnte. ARC.2 wählt dann selbständig brauchbare Experimente aus, während BACON diese Aufgabe der Benutzerin überläßt.

Kokar legt bei seinem System COPER [Kokar 1986] besonderen Wert darauf, bei der Kombination bestehender Variablen zu neuen Variablen auf die Kompatibilität der Einheiten (für Druck, Temperatur usw.) zu achten. Um über die Kompatibilität entscheiden zu können, muß bekannt sein, welche Variablen überhaupt relevant sind. Dazu wird ein Verfahren angewandt, das die Vollständigkeit der Menge von Variablen ermittelt, die den zugrundeliegenden physikalischen Prozeß charakterisieren. Dadurch können sowohl irrelevante Variablen ermittelt werden als auch relevante, aber fehlende Variablen.

Bei einigen Verfahren muß bekannt sein, welche Variable in den Eingabedaten die abhängige ist. Mit diesem Wissen reduziert sich der Aufwand für die Suche, da Funktionsmodelle mit einer anderen Variablen als abhängige Variable nicht mehr überprüft werden müssen. Das ist z.B. bei EF der Fall (vgl. mit der oben angegebenen Form der Eingaben). Die Anzahl der Variablen, die in den

Eingabedaten vorkommen dürfen, variiert ebenfalls je nach Verfahren. So berücksichtigt EF nur zwei Variablen, bei anderen Verfahren, z.B. BACON, wird die Anzahl nicht beschränkt. Für das in Kapitel 1 vorgestellte Problem gilt, daß die abhängige Variable bekannt ist. Sie hängt im Prinzip nur von einer anderen Variablen ab, nämlich dem Zeitpunkt der Messung. Die Meßdaten des Roboters enthalten zwar auch noch Werte für zahlreiche andere Variablen. Beim Zusammenfassen der Meßdaten müssen sie jedoch nur indirekt berücksichtigt werden. Verfahren, die die abhängige Variable selbständig bestimmen, berücksichtigen diese zeitliche Abfolge der Meßdaten nicht. Dadurch wird einerseits ein unnötig hoher Aufwand betrieben, andererseits entdecken die Verfahren möglicherweise eine - zufällig vorhandene - umgekehrte Abhängigkeit. Ein solches Ergebnis wäre aber für das Problem aus Kapitel 1 nicht zu gebrauchen.

Systeme wie IDS und FAHRENHEIT integrieren alle drei oben erwähnten Bereiche des Maschinellen Entdeckens. Sie entdecken Begriffshierarchien, qualitative und quantitative Regularitäten. Die Komponente zum Entdecken quantitativer Regularitäten verwendet dabei den üblichen Ansatz von BACON.

2.1.2.2 E*

Schaffer [Schaffer 1990] verfolgt mit ihrem Verfahren E* einen anderen Ansatz als die bisher vorgestellten Systeme. Hier wird die Bestimmung einer Funktion nicht als Suche in einem unendlichen Raum von Funktionsmodellen sondern als Klassifikationsproblem angesehen: es wird entschieden, welches der vorgegebenen Funktionsmodelle paßt. Vorgegeben werden lediglich acht verschiedene mögliche Ergebnisse: ein lineares Modell $y = k_1x + k_2$, sechs einfache Modelle höheren Grades $y = kx^n$ mit $n \in \{-2, -1, -0.5, 0.5, 1, 2\}$ und die Antwort „keine Beziehung gefunden“. Ausgabe des Verfahrens ist maximal eine der vorgegebenen Funktionen. E* setzt also ebenfalls die Homogenität des Datenraumes voraus. Betrachtet werden nur zwei Variablen, wobei die abhängige Variable bekannt ist. Eine zeitliche Abfolge von Daten würde dadurch also berücksichtigt. Fehler in den Eingabedaten werden bei diesem Ansatz ignoriert.

Begründet wird die Vorgabe einfacher Funktionsmodelle und der Antwort „keine Beziehung gefunden“ folgendermaßen: Betrachtet man sich die funktionalen Beziehungen, die WissenschaftlerInnen im *Physical Review* für Daten vorgeschlagen haben, so finden sich in rund 70% der Fälle die gleichen einfachen Funktionen. BACON findet bei diesen Daten auch nur einfache Beziehungen, obwohl der Algorithmus so angelegt ist, daß er auch komplizierte Beziehungen entdecken kann. Kokar [Kokar 1986] ist ebenfalls der Ansicht, daß es für die meisten physikalischen Gesetze ausreicht, einfache Funktionsmodelle zu berücksichtigen. Er beschränkt die Suche in COPER daher auf lineare Funktionen und Polynome 2. Grades.

E* testet zunächst, ob ein Modell höheren Grades geeignet ist. Für alle sechs Funktionsmodelle $y = kx^n$ wird der Koeffizient k mittels Regression bestimmt. Für x und kx^n (jetzt mit dem berechneten Koeffizienten) wird jeweils die Korrelation R

berechnet und durch die monotone Transformation $MF = \frac{1}{1-R^2}$ verstärkt¹⁰. Die Funktion mit dem höchsten Wert für MF wird zur aussichtsreichsten Kandidatin für die gesuchte Gleichung. Ein Kriterium für die Entscheidung, ob es sich bei der aussichtsreichsten Kandidatin tatsächlich um die gesuchte Gleichung handelt, ist das Maß D. D wird berechnet als Differenz

höchster Wert für MF - zweithöchster Wert für MF.

Je größer der Wert für D ist, desto besser kann man das Modell mit dem höchsten Wert unterscheiden von den übrigen.

Das zweite Kriterium für die Entscheidung, ob es sich um die gesuchte Gleichung handelt, ist die Signifikanz des berechneten Koeffizienten k. Wenn beispielsweise die Funktion $y = kx^n$ betrachtet wird, würde man in der Statistik den Koeffizienten k auf seine statistische Signifikanz testen. D.h. man möchte zeigen, daß es unwahrscheinlich ist, aus den zugrundeliegenden Daten einen Wert für k zu berechnen, der ungleich 0 ist, wenn er tatsächlich 0 sein müßte. Die Signifikanz der Funktion $y = kx^n$ wird indirekt getestet. E* wendet dazu Regression auf das komplexere Funktionsmodell $y = k_1x^n + k_2$ an und bestimmt den optimalen Wert für k_2 . Die Signifikanz t von k_2 wird dann mit der t-Statistik¹¹ bestimmt. Ein großer absoluter Wert zeigt an, daß es unwahrscheinlich ist, daß ein Wert $\neq 0$ für k_2 nur auf zufällige Schwankungen der Daten zurückzuführen ist, also der Wert $\neq 0$ für k_2 signifikant ist. Das spricht natürlich gegen die einfachere Funktion ohne den Summanden k_2 .

Eine Kombination der Werte D und t wird für die endgültige Entscheidung, ob die bisher favorisierte Funktion den Zuschlag erhält, herangezogen. Um ein geeignetes Kriterium für die Kombination zu bestimmen, wurden für zahlreiche Mengen von Datensätzen aus *Physical Review* die Werte D und t berechnet. Für diese Mengen von Datensätzen war bekannt, welche Funktionen von PhysikerInnen zur Beschreibung der Daten ermittelt worden waren. Die Funktion, die von E* jeweils favorisiert würde, wurde nun einfach in ein Koordinatensystem eingetragen, bei dem auf der x-Achse die Werte für D abgetragen wurden und auf der y-Achse die Werte für t. Wenn die von E* favorisierte Funktion übereinstimmte

¹⁰ Schaffer charakterisiert R^2 als einen in der Statistik üblichen Wert und gibt als Beispiel die Werte 0,9891 und 0,9981 für R^2 . Mit der vorgeschlagenen Transformation ergeben sich die Werte 91,74 und 526,3 für MF.

Genaugenommen handelt es sich bei der Aussage, daß R eine Korrelation ist, nur um eine Hypothese. Dafür spricht, daß die Korrelation zwischen zwei beobachteten Größen ein sehr häufig bestimmter Wert in der Statistik ist, die die Abhängigkeit zwischen diesen Größen durch einen Wert aus $[-1,1]$ ausdrückt. Durch das Quadrieren geht ein Teil der Information verloren.

Bei der monotonen Transformation müßten die Werte -1 und 1 für R jedoch ausgeschlossen werden, worauf Schaffer nicht hinweist.

¹¹ Die t-Statistik überprüft für zwei Verteilungen mit gleicher Varianz die Lagealternativen (siehe z.B. [Hartung et al. 1982]). Die Beziehung zur Signifikanz von k_2 wird hier leider nicht klar. Schaffer weist jedoch bei allen verwendeten statistischen Verfahren auf ihre Dissertation hin, die näher auf diese Verfahren eingehen soll.

mit der von PhysikerInnen ermittelten Funktion, wurde + eingetragen, sonst -. Diese Eintragungen ließen sich recht gut „von Hand“ mit einer Geraden in zwei Cluster einteilen. Die zugehörige Geradengleichung dient dann als Kriterium für die Entscheidung gegen oder für die bisher favorisierte Funktion.

Wird nach diesem Kriterium die Funktion abgelehnt, wird als nächstes das lineare Modell geprüft. Wenn die Koeffizienten k_1 und k_2 durch Regression bestimmt sind, wird für die lineare Funktion $k_1x^n + k_2$, $n = 1$, und für zwei ähnliche Funktionen (mit etwas kleinerem und mit etwas größerem n) wieder der MF-Wert berechnet. Die lineare Funktion muß den höchsten Wert haben, andernfalls wird sie abgelehnt. Sie wird ebenfalls abgelehnt, wenn der Absolutwert von t für mindestens einen der beiden Koeffizienten k_1 und k_2 kleiner ist als 2.

Als drittes Kriterium wird schließlich noch überprüft, ob bei der Beschreibung der Daten durch die lineare Funktion nicht doch ein systematischer Fehler gemacht würde. Dazu werden für alle x -Werte der Daten die Differenzen r zwischen tatsächlichem y -Wert und von der Funktion vorhergesagtem y -Wert. Zwischen der Variablen x und den Differenzen darf es keine Beziehung geben, insbesondere keine Beziehung der Form $r = k_3x^2 + k_4x + k_5$. Andernfalls ist die lineare Funktion keine angemessene Beschreibung der Daten, ein Polynom höheren Grades wäre besser geeignet¹². Wenn das Polynom höheren Grades aber im ersten Schritt nicht entdeckt wurde, wird es sich um ein komplizierteres Polynom handeln, das nicht zu den sechs vorgegebenen gehört. Um zu testen, ob eine Beziehung der Form $r = k_3x^2 + k_4x + k_5$ in den berechneten Differenzen zu finden ist, werden mittels Regression die optimalen Koeffizienten k_3 , k_4 und k_5 und für sie die t -Werte berechnet. Wenn einer der t -Werte größer ist als 5, wird ein systematischer Fehler angenommen, und die lineare Funktion wird abgelehnt. In dem Fall konnte also keine geeignete Funktion ermittelt werden. Andernfalls wird die lineare Funktion ausgegeben.

Bei diesem Ansatz wird das Prinzip „so einfach wie möglich“ an einigen Stellen deutlich. So führt etwa die Betrachtung zahlreicher realer Daten zu der Erkenntnis „Warum sollte man komplizierte Funktionsmodelle in Erwägung ziehen, wenn in den meisten Fällen ganz einfache Modelle ausreichen?“ Dem gleichen Prinzip entspricht auch die Methode „Clusterbildung von Hand“ für das Festlegen einer Grenze zwischen abzulehnenden und zu akzeptierenden Funktionen. Dem Prinzip „so einfach wie möglich“ wird die Leserin auch bei dem in den Kapiteln 3 und 4 vorgestellten Verfahren an einigen Stellen begegnen.

2.1.2.3 Bewertung der Verfahren des Maschinellen Entdeckens

Für die im Rahmen des B-Learn II-Projektes zu lösende Aufgabe stellt sich die Frage, ob es sinnvoll ist, komplexe Zusammenhänge in den Meßdaten zu

12 Schaffer untersucht hier also, wie die Daten von der linearen Funktion abweichen. In der Statistik sind Verfahren mit dieser Vorgehensweise unter der Bezeichnung Residuenanalyse bekannt. Als Residuen bezeichnet man die Differenzen zwischen tatsächlichem y -Wert und von der Funktion bestimmtem y -Wert.

bestimmen. Vielleicht reichen ja einfache Beziehungen völlig aus! In betracht zu ziehen ist bei dieser Überlegung, wie die Verarbeitung der Meßdaten prinzipiell erfolgen soll. Wie in Kapitel 1 dargestellt, sind die für die Navigation benötigten Informationen durch die Verarbeitung zu ermitteln. Um welche Art von Informationen es sich handelt, wird vorgegeben in Form einiger qualitativer Merkmale. Was die Verarbeitung noch zu leisten hat, ist, festzustellen, welche Meßdaten man zusammenfassen und mit einem bestimmten Merkmal bezeichnen sollte. Hat man nun die Meßdaten eingeteilt und Funktionsgleichungen jeweils für eine Menge von Meßdaten bestimmt, müssen diese Funktionsgleichungen noch geeignet abgebildet werden auf die vorgegebenen qualitativen Merkmale. Diese Merkmale sind recht einfacher Natur, sie drücken lediglich Tendenzen aus wie „gleichbleibend“ oder „ansteigend“. Der rechnerische Aufwand für die Bestimmung einer relativ komplexen Funktionsgleichung, die dann die Meßdaten sehr gut annähert, ist natürlich vergeblich, wenn sie schließlich doch wieder auf eines von wenigen, einfachen Merkmalen abgebildet werden soll.

Ein weiteres Problem fast aller Ansätze des Maschinellen Entdeckens ist, wie schon gesagt, die Annahme der Homogenität des Datenraumes. Das in Kapitel 1 genannte Ziel, die Sensordaten geeignet zusammenzufassen, kann mit Verfahren, denen diese Annahme zugrunde liegt, nicht erreicht werden. Bei diesen Verfahren würden viele Meßpunkte mit einem großen Abstand z.B. zur berechneten Regressionsgerade automatisch als Ausreißer eingestuft, also als untypische Daten, die ignoriert werden sollten. Falkenhainer und Michalski [Falkenhainer und Michalski 1986] weisen auf die in der statistischen Literatur genannten Techniken hin, wie man von Hand Ausreißer eliminieren kann, bevor irgendein Verfahren auf die Daten angewendet wird. ABACUS beispielsweise kann diese untypischen Daten automatisch eliminieren. Im Roboter-Szenario dürfen diese Daten jedoch nicht einfach eliminiert werden, denn es könnte sich um wichtige Informationen handeln. Wenn etwa der Roboter parallel an einer Wand entlang fährt, sind die gemessenen Distanzen mehr oder weniger identisch. Ein kleines Objekt zwischen Roboter und Wand führt zu einigen wenigen abweichenden Distanzen. Will man aber gerade dieses Objekt erkennen, dürfen diese Distanzen nicht als Ausreißer behandelt werden, sondern müssen gesondert zusammengefaßt werden. Für einen untypischen Meßwert könnte natürlich auch ein Meßfehler verantwortlich sein. Es gibt jedoch keine Möglichkeit, bei „außergewöhnlichen“ Meßdaten zwischen Meßfehlern und Abweichungen mit hohem Informationsgehalt zu unterscheiden.

Um das zum Thema Homogenität Gesagte auf den Punkt zu bringen: Der Grund, warum man im Szenario aus Kapitel 1 nicht von der Homogenität des Datenraumes ausgehen darf, ist eine bestimmte Eigenschaft der Fahrten des Roboters. Bei einer Fahrt durch den Raum werden stets verschiedene Objekte erfaßt, die aber unterschieden werden müssen. Würden sich alle Meßdaten einer Fahrt nur auf ein Objekt beziehen, dann wäre die Annahme der Homogenität zumindest in einigen Fällen berechtigt. Das gilt etwa für eine Wand, nicht jedoch für eine Tür. Eine Tür besteht aus den senkrechten Teilen des Türrahmens und dem Durchgang dazwischen. Die Meßdaten für den Bereich des Türrahmens unterscheiden sich deutlich von denen für den Durchgang. Wollte man also im B-Learn II-Szenario für das Zusammenfassen der Meßdaten ein Verfahren anwenden, das Homogenität

voraussetzt, dürfte man pro Fahrt des Roboters nur Meßdaten für ein einziges „gerades“ Objekt sammeln - etwa für eine Wand, für den senkrechten Teil eines Türrahmens oder den Durchgang zwischen Türrahmen. Um zu lernen, welche Wahrnehmungen eine Tür kennzeichnen, reicht das aber nicht aus. Was noch fehlt, ist die Information über die Beziehung zwischen Türrahmen und Durchgang bezüglich des gemessenen Abstandes zum Roboter. Sich den gemessenen Abstand bei beiden „geraden“ Objekten zu merken, ist keine geeignete Strategie. Schließlich sollen nur wenige allgemeine Regel für den operationalen Begriff „an einer Tür vorbeifahren“ gelernt werden, und nicht unzählige Regeln für die Vorbeifahrt jeweils mit bestimmten Abständen von der Tür. Für eine „universelle“ Regel ist in irgendeiner Form die Information nötig, daß die gemessenen Abstände beim Türdurchgang größer sind als beim Türrahmen. Mit einem Verfahren, das von der Homogenität des Datenraumes ausgeht, wird man eine solche Information nicht erhalten.

Halten wir also als Gründe gegen die Verwendung von Verfahren des Maschinellen Entdeckens fest:

- die bei fast allen Verfahren fehlende Möglichkeit, mit inhomogenen Daten umzugehen,

Voraussetzung für die in Kapitel 1 geforderte Unterscheidbarkeit einzelner Objekte ist aber gerade der Umgang mit inhomogenen Daten!

- die bei vielen Verfahren fehlende Berücksichtigung der zeitlichen Abfolge der Meßdaten

und

- das bei allen Verfahren existierende Problem der Zuordnung eines geeigneten qualitatitven Merkmals

Maschinelles Entdecken ist eben keine Lösung für das *signal-to-symbol*-Problem!

2.2 Einteilen des Datenraumes

Wie schon gesagt kann die in Kapitel 1 genannte Bedingung, die Meßdaten verschiedener Objekte zu unterscheiden, nicht mit Verfahren erreicht werden, denen die Annahme der Homogenität des Datenraumes zugrunde liegt. Was fehlt, ist eine Methode, mit Hilfe derer zunächst eine sinnvolle Einteilung der Daten vorgenommen werden kann.

Gebräuchliche Verfahren zum Einteilen des Datenraumes stellen z.B. Connell und Mahadevan [Connell und Mahadevan 1993] vor. Sie unterscheiden zwischen Region-basierten und Punkt-basierten Verfahren.

Bei Region-basierten Verfahren wird der Datenraum in nicht-überlappende Bereiche eingeteilt, denen jeweils eine bestimmte Ausgabe, oder - gerade im Bereich der Robotik - eine bestimmte Handlung zugeordnet ist. Einer neuen Eingabe wird dann die Ausgabe bzw. die Handlung zugewiesen, die zu dem

Bereich gehört, in den die Eingabe gemäß der vom Verfahren bestimmten Klassifizierungsvorschrift fällt.

Ein Beispiel dafür ist das Verfahren von Friedman, Bentley und Finkel [Friedman et al. 1977], bei dem der Datenraum schrittweise aufgeteilt wird mit einer Geraden bzw. allgemein einer Hyperebene bei höherer Dimension. Dazu wird für jede Dimension die Varianz der entsprechenden Komponenten der Eingabepunkte berechnet. Gewählt wird die Dimension mit der größten Varianz, und die Hyperebene wird durch den Mittelwert dieser Komponenten (parallel zu einer anderen Achse) gelegt. Das Aufspalten einer Region in zwei Regionen wird unabhängig voneinander für alle Regionen fortgesetzt, bis sich nur noch Eingabepunkte mit gleichem Ausgabewert bzw. gleicher Handlung in einer Region befinden.

Ähnliche Verfahren sind die unter der Bezeichnung **C**lassification **A**nd **R**egression **T**rees [Breiman et al. 1984] bekannten Techniken. Sie versuchen den Datenraum einzuteilen gemäß der Maximierung der „Reinheit“ der Klassifizierungen der Daten in den entstehenden Unterbereichen. Es wird also im Gegensatz zu dem Verfahren von Friedman et al. nicht gefordert, daß alle Daten einer Region die gleiche Klassifizierung aufweisen. Diese strenge Forderung kann zu „*over-fitting*“ der entstehenden Klassifizierungsvorschriften führen, mit der Folge, daß sie sich sehr empfindlich gegenüber verrauschten Daten verhalten. Das Phänomen „*over-fitting*“ spielt auch bei dem in Kapitel 4 vorgestellten Verfahren eine große Rolle. Ein weiteres Beispiel für ein Region-basiertes Verfahren - diesmal aus dem Bereich des Maschinellen Lernens - ist ID3 [Quinlan 1986], das zur Einteilung des Datenraumes ein informationstheoretisches Maß verwendet.

Diese Verfahren ermitteln aus Beispielen - also Datensätzen mit einer Klassifikation - eine Klassifizierungsvorschrift, die es dann ermöglicht, Beobachtungen - also Datensätzen ohne Klassifikation - zu klassifizieren. Solche Techniken sind im Szenario, das für diese Diplomarbeit vorgegeben ist, nicht anwendbar. Es müssen in der Anwendungsphase die gleichen Abstraktionsschritte von den Meßdaten bis zu den operationalen Konzepten durchgeführt werden wie in der Lernphase. Verfahren, die eine Klassifizierungsvorschrift bestimmen, benötigen dazu die Klassifikation der Eingabedaten. Eine Klassifikation der Meßdaten steht jedoch nur in der Lernphase zur Verfügung, so daß in der Anwendungsphase der Abstraktionsschritt von den Meßdaten zu den Basiswahrnehmungsmerkmalen mit einem solchen Verfahren nicht durchgeführt werden könnte.

Ein Beispiel für ein Punkt-basiertes Verfahren ist das „Prinzip der k nächsten Nachbarn“, bei dem die Ausgabe zu einer neuen Eingabe durch Interpolation der Ausgaben ihrer k nächsten Nachbarn bestimmt wird.

Die Region- und Punkt-basierten Verfahren können also mit einem inhomogenen Datenraum umgehen, benötigen aber eine Klassifikation. Außerdem berücksichtigen sie bei der Einteilung der Daten nicht deren mögliche zeitliche Abfolge.

Rao und Lus [Rao und Lu 1992] Algorithmus ist ein Beispiel für ein Verfahren, mit dem der Datenraum eingeteilt werden kann, ohne daß eine Klassifikation der Eingabedaten nötig ist. Der Algorithmus wurde entwickelt zur Analyse von Meßdaten aus dem technischen Bereich. Von solchen Daten ist bekannt, daß die

Beziehung zwischen den Variablen in den meisten Fällen im Datenraum variiert [Rao und Lu 1992]. Im Gegensatz zu Verfahren zur Analyse von Daten aus dem physikalischen oder chemischen Bereich, bei denen fast immer ein homogener Datenraum vorausgesetzt wird, wird hier also die Notwendigkeit gesehen, den Datenraum einzuteilen.

Ähnlich wie bei E^* (siehe Kapitel 2.1.2.2) werden hier Funktionsmodelle vorgegeben, die dafür bekannt sind, daß sich Daten in technischen Bereichen damit beschreiben lassen.

Zunächst wird zufällig ein Funktionsmodell aus den vorgegebenen ausgewählt. Der folgende Schritt wird mehrmals durchgeführt:

Aus den Eingabedaten werden zufällig k Daten ausgewählt, wobei k die Anzahl der zu bestimmenden Koeffizienten des Funktionsmodells ist. Die Koeffizienten des Funktionsmodells werden berechnet mit Hilfe der ausgewählten Daten und Regression. Dieser Schritt wird mehrfach durchgeführt, man erhält also mehrere Funktionen. Für jede Funktion wird bestimmt, welchen Bereich der Daten sie abdeckt. Diese Entscheidung wird - wie üblich - anhand der Differenzen zwischen den Funktionswerte von f und den tatsächlichen Funktionswerten der Eingabedaten getroffen.

Wie oft dieser Schritt durchzuführen ist, wird bestimmt mit einer Formel, die schätzt, wieviele Schritte benötigt werden, um eine Funktion zu finden, die die Eingabedaten angemessen beschreibt. Bei dieser Formel werden von der Benutzerin vorzugebende Parameter berücksichtigt, z.B. der Anteil an Eingabedaten, die von einer Funktion mindestens abgedeckt werden sollen.

Zur Auswahl des am besten geeigneten Datenbereiches mit zugehöriger Funktion wird das **Minimum Description Length-Prinzip** [Rissanen 1985] eingesetzt. Beim MDL-Prinzip geht es darum, die Länge der Kodierung von Zahlen zu minimieren, indem Korrelationen zwischen ihnen und Häufigkeiten berücksichtigt werden. Es wird genau berechnet, wieviel Bits benötigt werden, um die gesamten Daten, also die Grenzen des Bereichs, die zugehörige Funktion und die nicht abgedeckten Daten zu kodieren. Der Bereich mit dem günstigsten Ergebnis wird ausgewählt. Für die restlichen Daten wird das gesamte Verfahren wiederholt.

Dieses Verfahren benötigt also keine Klassifikation und kann mit einem inhomogenen Datenraum umgehen. Allerdings wird auch hier keine zeitliche Abfolge der Meßdaten berücksichtigt.

Verfahren zur Analyse von Zeitreihen dagegen erfüllen diese letztgenannte Bedingung natürlich. Durch die Berücksichtigung der zeitlichen Abfolge der Meßdaten vereinfacht sich das Problem des Einteilens. Gesucht wird eine Unterteilung der Zeitachse, so daß nur aufeinanderfolgende Daten zusammengefaßt werden. Diese Bedingung ersetzt eine Klassifikation der Daten.

Wisotzki und Wysotzki [Wisotzki und Wysotzki 1993] stellen ein Verfahren zur Entwicklung von Klassifikationsvorschriften für Zeitreihen vor. Die Zeitreihen bestehen aus einer großen Anzahl zu verarbeitender Werte, die zudem verrauscht sein können. Für die aufgrund dieser Eigenschaften nötige Vorverarbeitung verwenden sie eine Approximation der Zeitreihe durch Splines. Normalerweise gibt man Anzahl und Lage der Stützstellen vor und berechnet dann die approximierenden Splines (siehe Kapitel 2.1.1.2). Das Verfahren von Wisotzki und

Wysotzki benötigt diese Vorgaben nicht, sondern ermittelt selbständig Anzahl und Lage der Stützstellen in zwei Stufen.

Im ersten Schritt wird ein agglomeratives Verfahren [Steinhausen et al. 1977] aus der Clusteranalyse verwendet, um eine initiale Einteilung der Meßdaten zu bestimmen. Bei den bisher vorgestellten Verfahren zum Einteilen des Datenraumes wurde ein top-down-Ansatz verwendet. Im Gegensatz dazu handelt es sich bei dem agglomerativen Verfahren um einen bottom-up-Ansatz. Ausgehend von der feinsten Einteilung der Meßreihe, bei der jeder Meßpunkt ein Cluster bildet, werden schrittweise jeweils zwei Cluster zusammengefaßt, und zwar gerade diejenigen, die die geringste Vergrößerung des Fehlers des Clustering bewirken. Als Maß für den Fehler wurde die Summe der quadrierten Differenzen zwischen Stützwert und Funktionswert des jeweiligen Splines gewählt. Das bedeutet, daß jedesmal, wenn zwei Cluster zusammengefaßt werden sollen, alle Möglichkeiten ausprobiert werden müssen. Beim Ausprobieren muß für jede Möglichkeit ein Teil der Spline-Approximation wiederholt werden, da sich für jede Möglichkeit etwas andere Stützstellen (Grenzen der Cluster) ergeben.

Mögliche Abbruchkriterien für diesen ersten Schritt:

- Überschreiten einer vorgegebenen Clusterzahl
- Überschreiten eines vorgegebenen maximalen Fehlers für ein Clustering
- Nicht-Erreichen einer bestimmten Verbesserung der Fehlerrate;

Vorgegeben wird ein Faktor p , und es wird gefordert, daß

$$\text{Fehler des neuen Clustering} * p \leq \text{Fehler des alten Clustering}.$$

Im Anschluß an die Bildung eines initialen Clustering wird als zweiter Schritt ein Austauschverfahren [Steinhausen et al. 1977] verwendet, um die Einteilung zu verbessern. Cluster für Cluster wird untersucht, ob die Zuordnung eines Meßpunktes am Rand eines Clusters zum benachbarten Cluster eine Verringerung des Fehlers bewirkt. Ist das der Fall, wird die entsprechende Zuordnung vorgenommen. Nach endlich vielen Schritten wird ein lokales Minimum des Fehlers erreicht. Auch bei diesem zweiten Schritt muß bei jedem getesteten neuen Clustering wieder eine Spline-Approximation durchgeführt werden.

Das Verfahren nimmt zwar selbständig mit einigen vorzugebenden Parametern - etwa der maximalen Clusterzahl - die Einteilung der Meßdaten und ihre Zusammenfassung zu Funktionsgleichungen vor, betreibt allerdings einen recht großen Aufwand. Diesen Aufwand kann man abschätzen durch

$$\sum_{i=1}^m (n - i) * a_1 + k * a_2$$

mit n = Anzahl der Meßdaten

m = vorgegebene Clusterzahl

a_1 = Aufwand für eine Spline-Approximation im ersten Schritt

a_2 = Aufwand für eine Spline-Approximation im zweiten Schritt

k = Anzahl der benötigten Schritte
bis zum Erreichen eines lokalen Fehler-Minimums

Der Aufwand für eine Spline-Approximation liegt - je nach Verfahren zur Lösung eines Gleichungssystems - bei n oder n^2 im ersten Schritt, bzw. bei m oder m^2 im zweiten Schritt des Verfahrens. Es ergibt sich also $O(n^2)$ oder $O(n^3)$. Dieser Aufwand ist absolut gesehen natürlich gar nicht so groß - die Aufgabe der Einteilung einer Zeitreihe läßt sich aber noch wesentlich einfacher lösen, wie Kapitel 3 zeigen wird.

2.3 Diskretisierung stetiger Variablen

Für die Lösung der in Kapitel 1 dargestellten Aufgabe sind auch Verfahren zur Diskretisierung stetiger Variablen in Betracht zu ziehen, denn sie versuchen ebenfalls Daten zusammenzufassen. Die Bedingung, mit inhomogenen Daten umgehen zu können, wird von Diskretisierungsverfahren also erfüllt.

Die meisten Klassifikationsverfahren setzen voraus, daß die Trainingsbeispiele nur diskrete Werte enthalten [Lee und Shin 1994]. Wenn ein Attribut stetige Werte annimmt, ist also eine Diskretisierung der Werte erforderlich, d.h. eine Abbildung auf Intervalle, denen ein diskreter Wert zugewiesen wird. Es gibt nur wenige Algorithmen, die eine geeignete Diskretisierung automatisch durchführen können [Lee und Shin 1994].

Normalerweise werden sehr einfache Diskretisierungsverfahren benutzt. Dazu gehört das Verfahren „gleiche Distanzen“, bei dem der Bereich zwischen Minimum und Maximum der Werte eines Attributes eingeteilt wird in n Intervalle gleicher Breite. Den Intervallen könnte man dann z.B. den Mittelwert der Intervallgrenzen zuweisen. Der Nachteil dabei ist, daß viel Information verloren geht, insbesondere wenn die Werte nicht gleichmäßig verteilt sind [Lee und Shin 1994], [Esposito et al. 1993]. Eine andere Methode ist „gleiche Häufigkeiten“. Die Intervalle werden dabei so gewählt, daß jedes Intervall ungefähr die gleiche Anzahl Trainingsbeispiele enthält. Diese einfachen Diskretisierungsverfahren benötigen keine Klassifikation und können mit inhomogenen Daten umgehen. Sie berücksichtigen jedoch eine zeitliche Abfolge der Daten nicht, denn für die Anwendung von Diskretisierungsverfahren müssen die zu diskretisierenden Attributwerte zunächst geordnet werden.

Einige Klassifikationsverfahren berücksichtigen die Klassifikation bei der Konstruktion von Intervallen. Um beispielsweise bei CART das Attribut auszuwählen, anhand dessen man die Beispiele am besten unterscheiden kann, werden die Attributwerte eingeteilt in zwei Intervalle. Die Grenze wird so gewählt, daß der Unterschied des Informationsgewinns beider Intervalle maximal wird. Die Übertragung des gleichen Prinzips auf statische Diskretisierungsverfahren¹³,

13 Verfahren, die während eines anderen Verfahrens angewendet werden, bezeichnet man als dynamische Verfahren. Statische Verfahren werden dagegen separat angewendet.

wenn eine Einteilung in mehr als zwei Intervalle vorgenommen werden soll, ist unklar. Aber auch wenn dynamische Verfahren wie oben möglich sind, wäre die Durchführung eines statischen Verfahrens vor dem Klassifikationsverfahren günstiger. Viele Algorithmen - beispielsweise zum Aufbau eines Entscheidungsbaumes - können z.B. gar nicht so viele Daten laden [Esposito et al. 1993]. In diesem Fall ist eine Reduzierung - etwa in Form einer statischen Diskretisierung - der Daten notwendig. Möglich ist auch, daß ein Verfahren bei dynamischer Diskretisierung viel zu viel Zeit benötigen würde [Henery 1994].

Lee und Shin [Lee und Shin 1994] schlagen für ein geeignetes, statisches Diskretisierungsverfahren vor, die Regeln, die man lernen will, zu berücksichtigen, d.h. das Zielattribut auch beim Diskretisierungsprozeß einzubeziehen.

Ihr Verfahren beginnt mit dem Sortieren der Trainingsbeispiele nach dem Wert für das Attribut, das zu diskretisieren ist. Zunächst bildet jedes Beispiel ein eigenes Intervall. Für jede Grenze zwischen zwei aufeinanderfolgenden Intervallen wird dann mit einer Entropie-Funktion der Unterschied des Informationsgehaltes der beiden Intervalle bezüglich des Zielattributes bestimmt.

Der Ansatz hat wegen der Verwendung eines Entropie-Maßes eine gewisse Ähnlichkeit mit ID3. Ein Entropie-Maß wird bei ID3 dazu verwendet, das Attribut zu bestimmen, mit dem man die Beispiele am besten einteilen kann. Hier geht es darum, Intervalle mit gleichem Informationsgehalt zu bilden.

Die Grenze, für die der kleinste Entropie-Wert berechnet wird, wird entfernt, d.h. die angrenzenden Intervalle werden zusammengefaßt. Es handelt sich also wieder um ein bottom-up-Verfahren. Das Verfahren wird fortgesetzt, bis die maximale vorgegebene Anzahl von Intervallen erreicht wird. Die Entropie-Funktion, die in diesem Verfahren benutzt wird, hat den Vorteil, daß sie in jedem Fall anwendbar ist. Die Autoren nennen weitere gebräuchliche Entropie-Funktionen, die aber in bestimmten Fällen nicht angewendet werden können, etwa weil ein Wert im Nenner 0 werden kann.

Lee und Shins Verfahren nimmt eine sinnvollere Diskretisierung vor als die beiden o.g. einfachen Verfahren, benötigt dazu aber eine Klassifikation. Wie bei jedem statischen Diskretisierungsverfahren müssen die zu diskretisierenden Attributwerte zunächst geordnet werden. Eine zeitliche Abfolge der Daten wird also nicht berücksichtigt.

2.4 Zusammenfassende Bewertung der vorgestellten Verfahren

Die meisten Gründe, die jeweils gegen einen Teil der vorgestellten Verfahren sprechen, wurden bereits genannt:

- Es wird eine Klassifizierung der Meßdaten vorausgesetzt,
 - es wird ein homogener Datenraum vorausgesetzt,
 - die zeitliche Abfolge der Daten wird nicht berücksichtigt
- und
- die Berechnungen sind für die im B-Learn II-Szenario zu lösende Aufgabe unnötig kompliziert.

Den vorgestellten Verfahren ist zudem gemeinsam, daß sie das *signal-to-symbol*-Problem nicht lösen.

Über eine Bedingung, die ebenfalls in Kapitel 1 an ein Verfahren zur Lösung der Aufgabenstellung gestellt wurde, ist bisher noch nichts gesagt worden: Das Verfahren muß die Meßdaten inkrementell verarbeiten. Diese Forderung soll hier zunächst noch einmal ausführlicher motiviert werden, als es in Kapitel 1 der Fall war.

Überlegen wir, was passiert, wenn alle Meßdaten des Roboters bekannt sein müssen, ehe man mit ihrer Verarbeitung beginnen kann. In der Lernphase stellt das kein Problem dar. Für die Anwendungsphase bedeutet es jedoch, daß der Roboter zunächst an allen interessanten Objekten, wie z.B. Türen, vorbeifährt und erst am Ende einer Fahrt durch den Raum feststellt, daß er in einem bestimmten Zeitraum eine Tür passiert hat. Das Ziel der Navigation ist aber - um beim Beispiel einer Tür zu bleiben - bei dem Befehl „Fahre durch die Tür“ auf die Wahrnehmungen, die die Vorbeifahrt an einer Tür charakterisieren, sofort zu reagieren durch

- Anhalten,
- sich zurück bewegen (gegebenenfalls auch Drehen) in eine Position, die die Fahrt durch die Tür ermöglicht,

und schließlich

- Fahren durch die Tür.

Da sowohl in der Lern- wie auch in der Anwendungsphase das gleiche Verfahren zur Verarbeitung der Meßdaten eingesetzt werden muß, kommt nur ein Verfahren in Frage, daß die Meßdaten des Roboters sofort, d.h. inkrementell verarbeitet, um ein sofortiges Reagieren auf Wahrnehmungen zu ermöglichen. Diese Forderung stellen Connell und Mahadevan [Connell und Mahadevan 1993] im übrigen an alle Lernverfahren für Roboter. Die inkrementelle Verarbeitung hat zudem den

technischen Vorteil, daß das Speichern der im allgemeinen großen Mengen an Meßdaten überflüssig wird.

Da alle in diesem Kapitel vorgestellten Verfahren nur angewendet werden können, wenn sämtliche Messungen schon bekannt sind, kann keines der Verfahren zur inkrementellen Verarbeitung der Meßdaten eingesetzt werden¹⁴.

Folglich bestand die Notwendigkeit, ein neues Verfahren zu entwickeln, um die in Kapitel 1 dargestellte Aufgabe zu lösen. In den folgenden beiden Kapiteln wird dieses neue Verfahren vorgestellt.

¹⁴ IDS erhebt zwar den Anspruch, inkrementell zu sein. Das gilt jedoch nur für die Komponenten des Systems, die Begriffshierarchien und qualitative Zusammenhänge entdecken. Beim Entdecken numerischer Regularitäten kann es vorkommen, daß alle bisher schon berücksichtigten Meßdaten noch einmal betrachtet werden müssen.

3 Generierung von Basiswahrnehmungsmerkmalen aus Sensordaten

In diesem Kapitel soll zunächst die grundlegende Idee des in dieser Diplomarbeit neu entwickelten Verfahrens verdeutlicht werden, ehe die Vorgehensweise detailliert beschrieben wird.

Das Prinzip besteht darin, Meßdaten, die der Roboter an aufeinanderfolgenden Zeitpunkten liefert, zusammenzufassen, sofern sie „ähnlich“ sind. Zusammenfassen bedeutet, daß nicht die Meßdaten der einzelnen Zeitpunkte gespeichert werden, sondern nur ein charakteristischer Wert für diese Daten. Ergänzt wird dieser Wert lediglich durch die Angabe, für welchen Zeitraum er die Messungen repräsentiert.

Das ist nun noch nichts Außergewöhnliches, denn schon einfache Clusterverfahren leisten das soeben Genannte. Von zentraler Bedeutung bei dem hier vorgestellten Verfahren ist, daß für die Daten, die der Roboter zu einem Zeitpunkt liefert, sofort entschieden wird, was mit ihnen zu geschehen hat. Das Verfahren ist also inkrementell und erfüllt damit die Voraussetzung, die in Kapitel 1 und 2 als Voraussetzung für den Einsatz bei der Navigation formuliert wurde.

Nehmen wir an, der aktuelle Zeitpunkt, an dem der Roboter eine Messung liefert, sei t . Es wurden bereits Meßdaten des Zeitraumes von $t-n$ bis $t-1$ zusammengefaßt (Abbildung 1).




Abb. 1

Für die aktuelle Messung - zum Zeitpunkt t - ist dann zu entscheiden, ob sie dem charakteristischen Wert der bisher zusammengefaßten Meßdaten ähnelt. Ist das der Fall, wird sie diesen Meßdaten hinzugefügt, indem

- der Zeitraum vergrößert wird um den Zeitpunkt der neu hinzugefügten Messung,

(Im Beispiel (Abbildung 2) wird er auf $t-n$ bis t vergrößert.)

- der charakteristische Wert geändert wird, so daß er alle zusammengefaßten Meßdaten repräsentiert
- und
- die Meßdaten des Zeitpunktes t „weggeworfen“ werden.

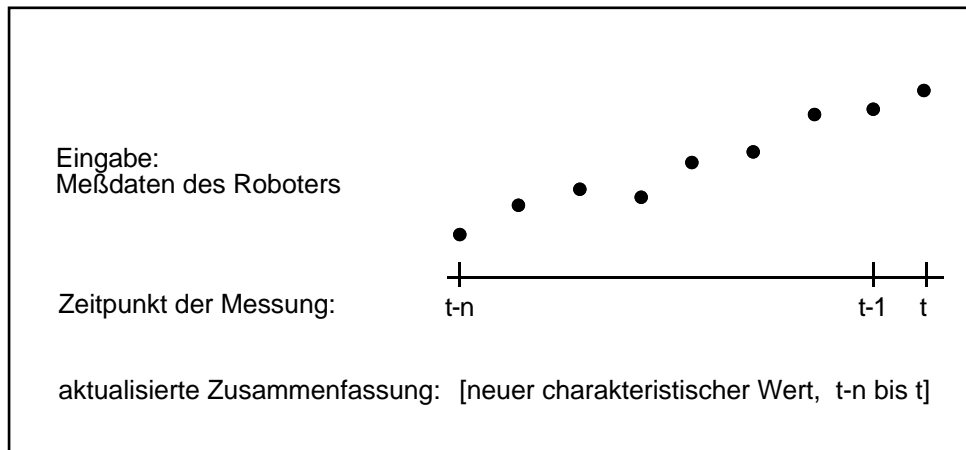


Abb. 2

Ähnelt die Messung zum Zeitpunkt t jedoch nicht dem charakteristischen Wert der bisher zusammengefaßten Meßdaten (Abbildung 3), wird die Messung nicht hinzugefügt. Die bisherige Zusammenfassung kann dann ausgegeben werden.

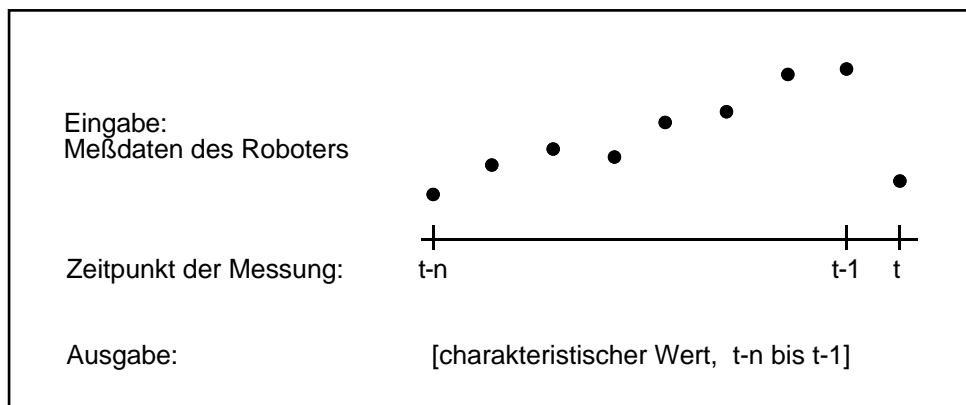


Abb. 3

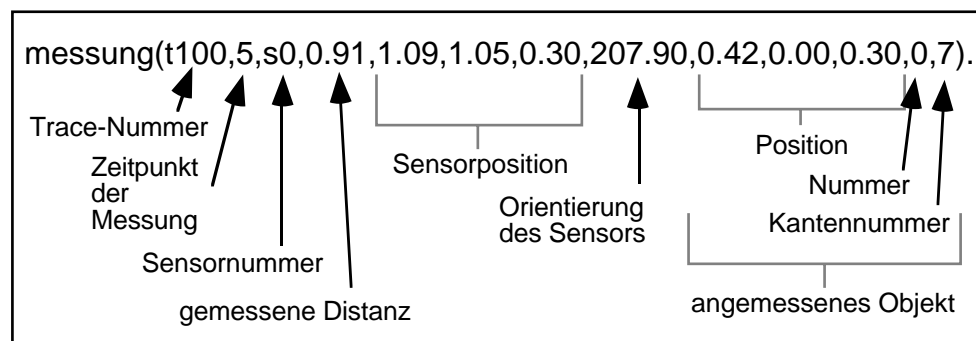
Für jeden weiteren Zeitpunkt ist wieder die gleiche Frage zu beantworten: Ähnelt die aktuelle Messung dem charakteristischen Wert der bisher zusammengefaßten Meßdaten oder nicht?

Bevor dieses Verfahren in Kapitel 3.2 präzisiert wird und insbesondere in Kapitel 3.2.2 die Kriterien für die Entscheidung „ähnlich oder nicht ähnlich“ minutiös dargestellt werden, sei zunächst die Repräsentation der Eingaben und Ausgaben des Verfahrens vorausgeschickt.

3.1 Repräsentation

Zu verarbeiten sind Daten, die die 24 Ultraschallsensoren eines Roboters bei einer Fahrt durch einen Raum liefern. Der Weg, den der Roboter nimmt, wird als **Trace** bezeichnet. Die Daten werden nicht direkt eingelesen, sondern von der sogenannten Datenhaltung, die das Zusammenspiel der einzelnen Systemkomponenten koordiniert, einer Vorverarbeitung unterzogen¹⁵. Die Vorverarbeitung liefert zwei Arten von Prolog-Fakten, die von dem hier vorgestellten Verfahren sequentiell eingelesen werden.

- 1) Zum einen sind das Fakten, im folgenden auch Datensatz¹⁶ genannt, die einen Großteil der numerischen Werte einer Messung enthalten, die ein Sensor imstande ist zu erfassen. Es existiert jeweils ein Faktum für jeden Zeitpunkt, an dem ein Sensor etwas gemessen hat.



¹⁵ Im momentanen Projektstadium existiert die Datenhaltung noch nicht. Sie ist als Teil einer anderen Diplomarbeit in Vorbereitung.

¹⁶ Mit Datensatz ist hier nicht eine Menge von Fakten gemeint, sondern nur ein Faktum.

Abb. 4

Von diesen Werten sind für die Verarbeitung nur die Trace-Nummer, die Sensornummer, der Zeitpunkt der Messung, die gemessene Distanz und die Orientierung des Sensors¹⁷ relevant.

Bei der Information über das angemessene Objekt handelt es sich um die Klassifikation, die bereits in Kapitel 1 erwähnt wurde. Sie steht nur in der Lernphase, nicht jedoch in der Anwendungsphase zur Verfügung. Daher kann sie für die Verarbeitung der Meßdaten, die ja auch in der Anwendungsphase durchgeführt werden muß, nicht genutzt werden.

Wie in Abbildung 4 ersichtlich bestehen die Angaben über das angemessene Objekt aus

- der Nummer des Objektes,
(Der Raum selbst hat eine Nummer und ebenso jedes Objekt im Raum, etwa ein Schrank.)
- der Nummer der Kante
(Als Kanten werden die geraden Linien eines Raumes und eines Objektes im Raum bezeichnet, also die Wände, die Türrahmen und die Seiten und Fronten von Schränken. Die Kanten des Raumes und jedes Objektes werden separat durchnummeriert.)




Abb. 5

und

- der Position des angemessenen Punktes im globalen Koordinatensystem.

¹⁷ Die Angaben zu Positionen und Orientierungen beziehen sich auf ein globales Koordinatensystem, das für den Raum definiert ist, in dem sich der Roboter bewegt.

Obwohl die Information über die angemessene Kante bei der Verarbeitung der Meßdaten nicht verwendet werden kann, kommt ihr eine besondere Bedeutung zu, worauf jedoch erst Kapitel 3.3.2.1 näher eingeht.

- 2) Bei der zweiten Art von Fakten handelt es sich um diejenigen, die in erster Linie für die Generierung der Basishandlungsmerkmale (siehe Kapitel 1) relevant sind. Für die Verarbeitung der Meßdaten liefern sie die Information, mit Hilfe derer festzustellen ist, ob sich der Roboter zwischen zwei Meßzeitpunkten bewegt hat (siehe Kapitel 3.2.1).




Abb. 6

Ziel der Verarbeitung ist, wie bereits erwähnt, jeweils für einen Trace und einen Sensor die relevanten Werte der Sensordaten inkrementell zusammenzufassen, so daß nur noch die für die Navigation benötigten Informationen erhalten bleiben. Für die Navigation von Interesse ist ein Zeitintervall, in dem sich die Messungen annähernd gleichmäßig verändert haben (vgl. mit Abbildung 3).

Diese für die Navigation nötigen Informationen werden jeweils für einen bestimmten Sensor vom hier vorgestellten Verfahren in Form von **Basiswahrnehmungsmerkmalen** ausgegeben. Ein Basiswahrnehmungsmerkmal wird durch ein Prolog-Faktum mit sechs Argumenten dargestellt.

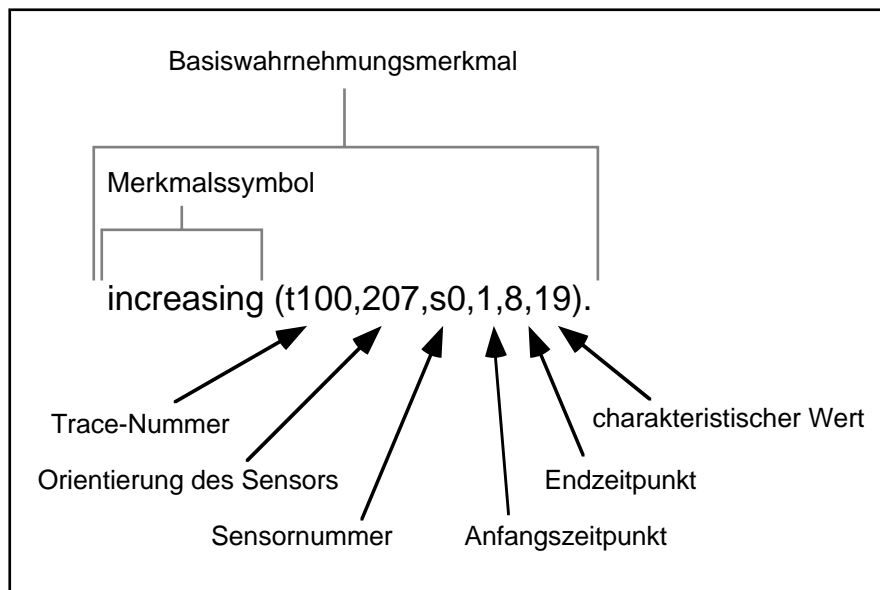


Abb. 7

Das Basiswahrnehmungsmerkmal in Abbildung 7 würde in der in Abbildung 3 dargestellten Situation ausgegeben. Anfangs- und Endzeitpunkt des Basiswahrnehmungsmerkmals geben das Zeitintervall an, in dem sich die Messungen annähernd gleichmäßig verändert haben. Die Trace-Nummer, die Sensornummer und die Orientierung des Sensors wurden aus den messungsfakten übernommen. Der charakteristische Wert wurde aus den Distanzen berechnet, die im Zeitintervall gemessen wurden. Auf diese Berechnung geht Kapitel 3.2.1.1 ein. Ein **Merkmalssymbol** ist ein Begriff, der die wesentlichen qualitativen Merkmale der im Zeitintervall zusammengefaßten Messungen beschreibt.

Im allgemeinen entsteht für einen Trace für jeden Sensor eine Sequenz solcher Basiswahrnehmungsmerkmale, z.B.

```

increasing (t100,207,s0,1,8,19).
decr_peak (t100,207,s0,8,9,-64).
increasing(t100,207,s0,9,42,34).
no_measurement(t100,207,s0,42,56,999)
no_movement(t100,207,s0,56,59,-999).
  
```

3.1.1 Aufgaben der Datenhaltung

Bisher wurde nur der Fall betrachtet, daß ein Sensor tatsächlich etwas gemessen hat. Das ist jedoch nicht zu jedem Zeitpunkt der Fall. Daher wird im folgenden unterschieden zwischen diesem Fall und dem Fall, daß eine Sensor nichts gemessen hat. Im erstgenannten Fall spricht man von einer erfolgreichen

Messung¹⁸, während im zweiten Fall von einer erfolglosen Messung die Rede ist. Wenn im folgenden allgemein von Messungen gesprochen wird, ist es entweder unerheblich, ob es sich um eine erfolgreiche oder eine erfolglose Messung handelt, oder es ist aus dem Kontext ersichtlich.

Zur Verarbeitung der Sensordaten wurde ein Algorithmus entworfen (siehe Kapitel 3.2.2) und implementiert, der jeweils die Datensätze eines Sensors inkrementell verarbeitet. Daraus und aus der Tatsache, daß für nicht erfolgreiche Messungen kein Datensatz existiert, ergibt sich folgendes Problem: bei Ausbleiben eines weiteren Datensatzes kann nicht entschieden werden, wann der Roboter innerhalb des Zeitraumes, in dem der Sensor keine erfolgreichen Messungen durchgeführt hat, evtl. einen Richtungswechsel vorgenommen hat. Drehungen werden erkannt durch die geänderte Orientierung des Sensors. Hat der Sensor aber zum Zeitpunkt t+x die gleiche Orientierung wie zum Zeitpunkt t, bedeutet das keineswegs, daß er sich nicht gedreht hat; beispielsweise hätte er sich in der Zwischenzeit um 90° nach rechts und dann wieder um 90° nach links drehen können. Unterscheiden sich die beiden Orientierungen, wurde eine Drehung durchgeführt. In welchem Zeitraum die Drehung erfolgte, ist jedoch nicht zu bestimmen.

Um den genauen Zeitpunkt bestimmen zu können, wird auch für erfolglose Messungen eines Sensors die Information über seine Orientierung benötigt. Die Datenhaltung muß also bei erfolgloser Messung eines Sensors für den jeweiligen Zeitpunkt ein Faktum generieren, das neben der Trace- und der Sensornummer die Orientierung des Sensors angibt. Als gemessene Distanz muß das Faktum einen Wert enthalten, der eindeutig von den gemessenen Distanzen bei erfolgreichen Messungen zu unterscheiden ist, etwa -1. Wie die Orientierung des Sensors bestimmt werden kann, wird in Kapitel 3.1.1.1 dargestellt.

Ebenso kann nicht entschieden werden, zu welchem Zeitpunkt der Trace beendet wurde: entweder definiert der Zeitpunkt des letzten verarbeiteten Datensatzes das Trace-Ende oder der Sensor hat im folgenden Zeitraum erfolglose Messungen durchgeführt. Da auch letztere Information von Bedeutung ist (siehe Kapitel 3.2.1.2), muß dem Algorithmus zur Generierung der Basiswahrnehmungsmerkmale zur Markierung des Trace-Endes von der Datenhaltung ein zusätzlicher Datensatz geliefert werden. Auch dieser Datensatz enthält neben der Trace- und der Sensornummer als gemessene Distanz einen Wert, der eindeutig von den gemessenen Distanzen bei erfolgreichen wie auch bei erfolglosen Messungen unterschieden werden kann, etwa -2. Als Zeitpunkt muß t gewählt werden, wobei zum Zeitpunkt t-1 die letzte erfolgreiche Messung sämtlicher Sensoren stattfand.¹⁹ Analog müssen aus technischen Gründen auch die roboterposition-Fakten um ein Faktum für diesen Zeitpunkt t ergänzt werden, wobei die Werte der Argumente unerheblich sind.

18 Eine Messung ist erfolgreich, wenn ein Objekt im Schallkegel des Sensors liegt und der Sensor die reflektierte Schallwelle innerhalb eines bestimmten Zeitraumes erfaßt.

19 Ob alle Sensoren zum Schluß noch einige erfolglose Messungen durchführen, kann von der Datenhaltung nicht festgestellt werden.

3.1.1.1 Algorithmus zur Vorverarbeitung der Sensordaten

Die Konvertierung der Meßdaten in Prolog-Fakten messung und roboterposition wird momentan von einem vom B-Learn-Mitarbeiter Volker Klingspor implementierten Algorithmus durchgeführt, der die Fakten jeweils in eine Datei schreibt. Zur Simulation der Eingaben von der Datenhaltung wurde ein Algorithmus entworfen und implementiert, der diese Fakten jeweils für einen Trace und einen Sensor, ergänzt um Fakten für alle erfolglosen Messungen und ein Faktum für das Trace-Ende, in eine neue Datei schreibt. Der Algorithmus zur Generierung der Basiswahrnehmungsmerkmale liest dann sequentiell die Fakten aus dieser Datei ein und verarbeitet sie.

Für eine erfolglose Messung eines Sensors s_Y zum Zeitpunkt t muß die Orientierung Or_Y des Sensors bestimmt werden. Falls es für diesen Zeitpunkt eine erfolgreiche Messung eines anderen Sensors, etwa s_X , gibt, läßt sich die gesuchte Orientierung Or_Y berechnen wie folgt: Die verwendete Orientierungsdifferenz $OrDiff_X$ ist der Winkel zwischen dem Sensor s_0 und dem Sensor s_X in mathematisch positiver Richtung. Er gibt die Lage eines Sensors s_X am Roboter an (analog für die Orientierungsdifferenz $OrDiff_Y$).

Der Algorithmus „berechne Orientierung“ wird aufgerufen mit den Eingaben s_Y und t und gibt Or_Y aus.

```
WENN es ein Faktum messung(Trace,sX20,t,_,_,_,_,OrX,_,_,_,_) . gibt
DANN setze  $Or_Y$  auf
      ( $Or_X + 360 - (OrDiff_X - OrDiff_Y)$ ) modulo 360

SONST WENN  $t > 1$ 
      DANN berechne Orientierung( $s_Y$ ,  $t-1$ ,  $Or_Y$ )
      SONST setze  $Or_Y$  auf -1
```

Falls zum Zeitpunkt t kein Sensor eine erfolgreiche Messung durchgeführt hat, wird also die Orientierung des Sensors s_X zum Zeitpunkt der letzten erfolgreichen Messung vor t bestimmt. Sie existiert nur dann nicht, wenn im gesamten Trace kein Sensor eine erfolgreiche Messung durchgeführt hat. Es existiert kein Datensatz, und es können auch keine Fakten für erfolglose Messungen und für das Trace-Ende ergänzt werden, da letztere Information fehlt, so daß hier nur leere Dateien erzeugt werden. Der Algorithmus zur Generierung der Basiswahrnehmungsmerkmale stoppt beim Versuch, aus einer leeren Datei zu lesen.

In der späteren Lernphase und der Anwendungsphase ist es im Fall, daß zum Zeitpunkt t kein Sensor eine erfolgreiche Messung durchgeführt hat, nicht möglich, die vorherigen Datensätze heranzuziehen, um die Orientierung eines

20 D.h. irgendein Sensor hat im aktuellen Trace zum Zeitpunkt t etwas gemessen. Dieser Sensor wird mit s_X bezeichnet.

Sensors zu einem früheren Zeitpunkt zu bestimmen. Die Datenhaltung könnte aber jeweils das Roboterposition-Faktum heranziehen, um die Sensororientierung aus der Roboterorientierung - sie entspricht der Orientierung des Sensors s_0 - und der Orientierungsdifferenz des jeweiligen Sensors zu berechnen. Da diese Fakten für jeden Zeitpunkt existieren, wäre der genaue Zeitpunkt der Orientierungsänderung auch dann zu bestimmen, wenn kein Sensor zu diesem Zeitpunkt etwas gemessen hat.

Wie bereits in Kapitel 3.1 erwähnt, liefern die Roboterposition-Fakten die Information, mit Hilfe derer festzustellen ist, ob sich der Roboter zwischen zwei Meßzeitpunkten bewegt hat. Die Sensorposition bei den messung-Fakten liefert zwar ebenfalls diese Information, bei erfolglosen Messungen müßte die Position jedoch ebenso wie die Sensororientierung, die ja für die Basiswahrnehmungsmerkmale benötigt wird, berechnet werden. Die Roboterposition-Fakten existieren dagegen auch für erfolglose Messungen, und eine zusätzliche Berechnung erübrigt sich.

3.2 Das Verfahren zur Generierung der Basiswahrnehmungsmerkmale

In diesem Kapitel wird präzisiert, was bisher nur kurz angesprochen wurde, nämlich die einzelnen Schritte bei der Verarbeitung der Datensätze:

- Berechnung eines Winkels als charakteristischer Wert für die Änderung der gemessenen Distanzen je zweier aufeinanderfolgender Messungen (Kapitel 3.2.1.1)
bzw.
Zuweisung eines Winkels als charakteristischer Wert je zweier aufeinanderfolgender Messungen
Kapitel 3.2.1.2)
- Zusammenfassen ähnlicher Winkel in einem Zeitintervall (Kapitel 3.2.1.1, 3.2.1.2 und 3.2.2.2)
- Zuordnung eines Merkmalssymbols zu einem Zeitintervall (Kapitel 3.2.1.1 und 3.2.1.2)

3.2.1 Definition der Merkmalssymbole

Vorgegeben wird eine Reihe von Begriffen samt ihrer Definition, die die wesentlichen qualitativen Merkmale der Daten beschreiben. Diese Begriffe werden als **Merkmalssymbole** bezeichnet. Unter qualitativen Merkmalen sind solche zu verstehen, die die allgemeine Tendenz von Änderungen der gemessenen Distanzen jeweils eines Sensors beschreiben und damit eine gewisse Interpretation der Daten beinhalten hinsichtlich der Bewegung des

Sensors relativ zu dem angemessenen Objekt (siehe Kapitel 3.2.1.1). In einigen Fällen beziehen sich die Merkmalssymbole nicht auf ein angemessenes Objekt, etwa wenn ein Sensor in einem Zeitraum keine erfolgreichen Messungen durchgeführt hat (siehe Kapitel 3.2.1.2).

Im folgenden werden die Merkmalssymbole beschrieben. Dabei sind einige Sonderfälle von den übrigen Fällen abzugrenzen sowohl aus formalen wie auch aus inhaltlichen Gründen. Zunächst werden jedoch die Merkmalssymbole für die eigentlich interessierenden Fälle vorgestellt.

3.2.1.1 Merkmalssymbole für Normalfälle

Unter einem Normalfall sind zwei aufeinanderfolgende Messungen zu verstehen, für die gilt:

- die Messungen waren erfolgreich,
 - der Roboter ist im Zeitraum zwischen den beiden Meßzeitpunkten gefahren
- und
- der Roboter hat sich in diesem Zeitraum nicht gedreht.

Um den charakteristischen Wert für die Änderung der gemessenen Distanzen eines solchen Normalfalles zu bestimmen, werden folgende Daten verwendet:

Die Zeitpunkte der beiden Messungen seien $t-1$ und t .

- Position des Roboters zum Zeitpunkt $t-1$ =: $(X_{t-1}; Y_{t-1})$
- gemessene Distanz zum Zeitpunkt $t-1$ =: D_{t-1}
- Position des Roboters zum Zeitpunkt t =: $(X_t; Y_t)$
- gemessene Distanz zum Zeitpunkt t =: D_t

Berechnet wird der Winkel zwischen der x-Achse und der Strecke \overline{AB} , mit

$A = (0;0)$ und

$B = (a; D_t - D_{t-1})$, wobei a = Euklidischer Abstand zwischen $(X_{t-1}; Y_{t-1})$ und $(X_t; Y_t)$

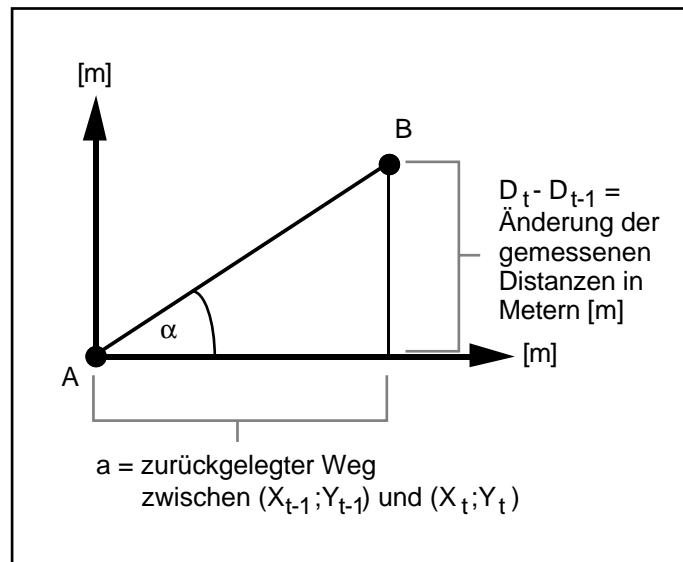


Abb. 8: Beispiel für den Fall $D_t \geq D_{t-1}$

Falls $D_t < D_{t-1}$, liegt der Winkel α im IV. Quadranten und hat ein negatives Vorzeichen.

Formel zur Berechnung von α :

$$\alpha = \arctan \frac{D_t - D_{t-1}}{a} = \arctan \frac{D_t - D_{t-1}}{\sqrt{(X_t - X_{t-1})^2 + (Y_t - Y_{t-1})^2}}$$

Der mathematische Grund, den Winkel α nicht zu berechnen, wenn der Roboter zwischen $t-1$ und t nicht gefahren ist, ist natürlich, daß in diesem Fall $a = 0$ gilt. Die Definition von Normalfällen am Anfang dieses Kapitels schließt daher diesen Fall aus. Auch bei den übrigen Fällen, die von dieser Definition nicht abgedeckt werden, ergeben sich Probleme, so daß diese Fälle ebenso einer gesonderten Behandlung bedürfen. Kapitel 3.2.1.2 geht auf diese Sonderfälle ein.

Wie geht es aber nun mit den Normalfällen weiter? Bisher wurde ein Winkel als charakteristischer Wert für die Änderung der gemessenen Distanzen zum Zeitpunkt $t-1$ und t berechnet. Die Meßdaten des Zeitpunktes $t-1$ sind somit verarbeitet und können „weggeworfen“ werden. Die Meßdaten des Zeitpunktes t

werden dagegen noch für die Berechnung des folgenden Winkels benötigt, können danach aber ebenfalls „weggeworfen“ werden.

Der nächste Schritt ist dann die Entscheidung, ob der soeben berechnete charakteristische Wert der beiden Messungen dem charakteristischen Wert der bislang zu einem Zeitintervall zusammengefaßten Meßzeitpunkte ähnelt. Nach welchen Kriterien die Entscheidung „ähnlich oder nicht ähnlich“ getroffen und wie der Intervall-Winkel aktualisiert wird, steht für die hier betrachteten Normalfälle in Kapitel 3.2.2.2.

Bei diesem charakteristischen Wert für ein Zeitintervall handelt es sich ebenfalls um einen Winkel. Er wird aktualisiert, falls das Intervall um den jeweils aktuellen Meßzeitpunkt erweitert wird, so daß er stets alle Winkel repräsentiert, die jeweils für zwei aufeinanderfolgende Meßzeitpunkte im Intervall berechnet wurden. Im folgenden wird dieser charakteristische Wert für ein Zeitintervall als **Intervall-Winkel** bezeichnet.

Gehen wir davon aus, daß die Entscheidung „nicht ähnlich“ lautet. Dann stehen die Werte für alle sechs Argumente des Prolog-Faktums, das ein Basiswahrnehmungsmerkmal repräsentiert, fest: Die Trace-Nummer, die Sensororientierung und die Sensornummer sind aus den Meßdaten bekannt, Anfangs- und Endzeitpunkt des Basiswahrnehmungsmerkmals entsprechen den Grenzen des Zeitintervalls, und der charakteristische Wert des Basiswahrnehmungsmerkmals ist gerade der Intervall-Winkel.

Die folgende Abbildung greift das Beispiel aus Abbildung 3 wieder auf und zeigt die bislang bestimmten Intervall-Winkel. Für das neue Intervall, das bei Zeitpunkt 8 beginnt, wurde erst ein einziger Winkel berechnet. Er ist gleichzeitig der vorläufige Intervall-Winkel. Bei der Verarbeitung der Messung zum Zeitpunkt 10 ist wieder zu entscheiden, ob das Intervall fortgesetzt und der Intervall-Winkel aktualisiert wird oder ob das Intervall bereits bei Zeitpunkt 9 wieder beendet und der vorläufige Intervall-Winkel beibehalten wird.

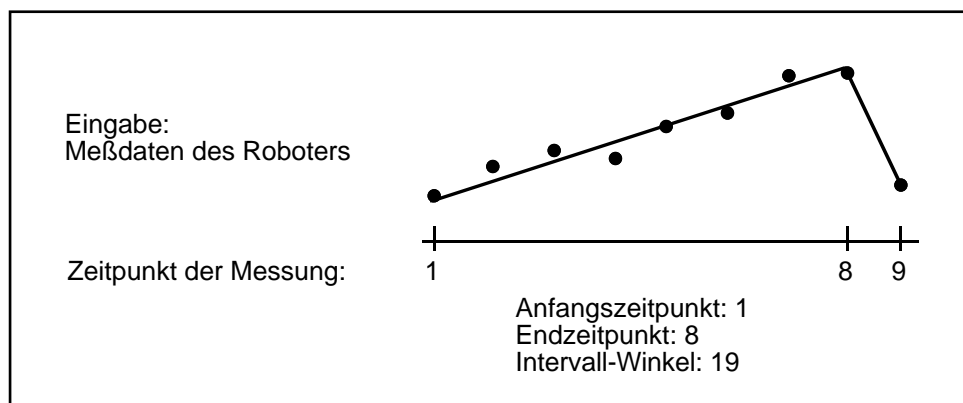


Abb. 9

Was jetzt noch fehlt, um ein Basiswahrnehmungsmerkmal ausgeben zu können, ist ein passendes Merkmalssymbol. Ein Merkmalssymbol hat zum einen die technische Funktion, Funktor für das Prolog-Faktum zu sein. Zum anderen soll das

Merkmalsymbol betonen, daß es sich bei einem Basiswahrnehmungsmerkmal tatsächlich um ein qualitatives Merkmal handelt. Die wesentliche Information, nämlich die allgemeine Tendenz von Änderungen der gemessenen Distanzen, ist bereits implizit in den letzten drei Argumenten eines Basiswahrnehmungsmerkmals enthalten. Das Merkmalsymbol jedoch nennt sie explizit.

Die Kriterien für die Auswahl eines passenden Merkmalsymbols aus den vorgegebenen Begriffen sind also die letzten drei Argumente des Prolog-Faktums, d.h. der Anfangs- und Endzeitpunkt des Basiswahrnehmungsmerkmals und der Intervall-Winkel. Letzterer gibt für das Zeitintervall des Basiswahrnehmungsmerkmals an, wie sich die gemessenen Distanzen während dieses Zeitraumes verändert haben: bei einem negativen Intervall-Winkel verringerten sie sich, bei einem positiven Intervall-Winkel wurden sie größer. Der Absolutwert des Intervall-Winkels ist ein Maß dafür, wie stark sich die gemessenen Distanzen im Vergleich zum zurückgelegten Weg verändert haben. Neben dem Intervall-Winkel ist die Länge des Zeitintervalls von Bedeutung, d.h. die Differenz Endzeitpunkt - Anfangszeitpunkt des Intervalls.

Die folgenden Merkmalsymbole stehen für Normalfälle zur Verfügung:

- *straight_to*

Für die Zuordnung dieses Merkmalsymbols muß der Intervall-Winkel im Bereich

$[-50;-40]$ liegen, und die Länge des Zeitintervalls muß größer sein als 1.

Hier wird aus der Tatsache, daß die gemessenen Distanzen sich von einem Meßzeitpunkt zum nächsten jeweils ungefähr um die in dieser Zeit zurückgelegte Distanz verringert haben, geschlossen, daß sich der Roboter direkt auf das sensorisch erfaßte Objekt zu bewegt.

Der Bereich für den Intervall-Winkel erklärt sich folgendermaßen: verringern sich die gemessenen Distanzen von einem Meßzeitpunkt zum nächsten genau um die in dieser Zeit zurückgelegte Distanz, wird ein Winkel von 45° berechnet. Es sollen aber durch dieses Merkmalsymbol auch die Fälle abgedeckt werden, in denen die beiden Distanzen nur ungefähr gleich groß sind. Daher wird der Bereich für den Intervall-Winkel ausgedehnt auf bis zu 5° kleinere und größere Werte.

- *straight_away*

Dieses Merkmalsymbol wird zugeordnet, wenn der Intervall-Winkel im Bereich $[40;50]$ liegt. Die Länge des Zeitintervalls muß größer sein als 1.

Hier wird aus der Tatsache, daß die gemessenen Distanzen sich von einem Meßzeitpunkt zum nächsten jeweils ungefähr um die in dieser Zeit zurückgelegte Distanz vergrößert haben, geschlossen, daß sich der Roboter direkt vom sensorisch erfaßten Objekt weg bewegt.

Der Bereich für den Intervall-Winkel wurde analog zu dem Bereich für *straight_to* festgelegt.

- *decr_peak*

Dieses Merkmalssymbol wird zugeordnet, wenn der Intervall-Winkel im Bereich $] -90; -50[$ ²¹ liegt. Die Länge des Zeitintervalls ist irrelevant.

Das Merkmalssymbol drückt aus, daß sich die gemessenen Distanzen im Zeitintervall im Vergleich zur zurückgelegten Distanz sehr stark verringert haben. Der erlaubte Bereich für den Intervall-Winkel umfaßt gerade die Werte, die kleiner sind als die bei *straight_to* erlaubten.

Wenn einem Zeitintervall dieses Merkmalssymbol zugewiesen wurde, kann das folgendermaßen interpretiert werden: innerhalb des Zeitintervalls wechselte die Kante, die vom Sensor erfaßt wird. Zunächst wurde eine Kante angemessen, die weiter vom Roboter entfernt liegt, dann wurde eine Kante erfaßt, die dem Roboter näher liegt.

- *incr_peak*

Dieses Merkmalssymbol wird zugeordnet, wenn der Intervall-Winkel im Bereich $] 50; 90[$ ²² liegt. Die Länge des Zeitintervalls ist irrelevant.

Das Merkmalssymbol drückt aus, daß sich die gemessenen Distanzen im Zeitintervall im Vergleich zur zurückgelegten Distanz sehr stark vergrößert haben. Der erlaubte Bereich für den Intervall-Winkel umfaßt gerade die Werte, die größer sind als die bei *straight_away* erlaubten.

Aus der Veränderung der gemessenen Distanzen im Vergleich zum zurückgelegten Weg kann ebenfalls geschlossen werden, daß innerhalb dieses Intervalls die Kante, die vom Sensor erfaßt wird, wechselt. In diesem Fall wurde jedoch zunächst eine Kante angemessen, die dem Roboter näher liegt, dann wurde eine Kante erfaßt, die weiter vom Roboter entfernt liegt.

- *stable*

Voraussetzung für die Zuordnung dieses Merkmalssymbols ist, daß der Intervall-Winkel im Bereich $[-3; 3]$ liegt und die Länge des Zeitintervalls größer ist als 1.

In diesem Fall gab es so gut wie keine Änderung der gemessenen Distanzen.

21 Ein Intervall-Winkel von -90° kann nur erreicht werden, wenn für den Winkel α für aufeinanderfolgende Meßzeitpunkte im Zeitintervall Werte berechnet wurden, die höchstens -90° betragen (vgl. mit den Methoden zur Berechnung des Intervall-Winkels in Kapitel 3.2.2.2). Das kann jedoch nicht vorkommen, da der Definitionsbereich des Arcustangens $] -90; 90[$ ist.

Im Fall Intervall-Winkel = -50° wird das Merkmalssymbol *something_happened* zugewiesen. Ebenso ist bei den übrigen Merkmalssymbolen dieser „Grenzfall“ willkürlich einem der beiden Merkmalssymbole mit benachbartem Bereich für den Intervall-Winkel zugeordnet worden.

22 Aus dem gleichen mathematischen Grund kann auch ein Intervall-Winkel von 90° nicht erreicht werden.

Verändern sich die gemessenen Distanzen gar nicht, wird jeweils ein Winkel von 0° berechnet. Durch die Ausdehnung des Bereiches für den Intervall-Winkel auf bis zu 3° kleinere und größere Werte sind auch geringe Veränderungen der gemessenen Distanzen noch erlaubt.

- *decreasing*

Für die Zuordnung dieses Merkmalssymbols muß der Intervall-Winkel im Bereich

$[-40;-3[$ liegen und die Länge des Zeitintervalls muß größer sein als 1.

Das Merkmalssymbol drückt aus, daß sich die gemessenen Distanzen im Zeitintervall im Vergleich zur zurückgelegten Distanz verringert haben. Der Bereich für den Intervall-Winkel umfaßt gerade die Werte zwischen denjenigen, die für *straight_to* und denen, die für *stable* erlaubt sind.

- *increasing*

Für die Zuordnung dieses Merkmalssymbols muß der Intervall-Winkel im Bereich

$]3;40]$ liegen und die Länge des Zeitintervalls muß größer sein als 1.

Das Merkmalssymbol drückt aus, daß sich die gemessenen Distanzen im Zeitintervall im Vergleich zur zurückgelegten Distanz vergrößert haben. Der Bereich für den Intervall-Winkel umfaßt gerade die Werte zwischen denjenigen, die für *straight_away* erlaubt sind, und denen, die für *stable* erlaubt sind.

- *something_happened*

Voraussetzung für die Zuordnung dieses Merkmalssymbols ist, daß der Intervall-Winkel im Bereich $[-50;50]$ liegt und die Länge des Zeitintervalls 1 beträgt.

Das Merkmalssymbol drückt aus, daß sich die gemessenen Distanzen im Zeitintervall im Vergleich zur zurückgelegten Distanz stark verändert haben. Der Bereich für den Intervall-Winkel umfaßt die Werte zwischen denjenigen, die für *decr_peak* erlaubt sind, und denen, die für *incr_peak* zugelassen sind.

Die geringe Länge des Zeitintervalls kommt zustande, wenn die Änderungen der gemessenen Distanzen in den benachbarten Zeitintervallen stark abweichen von der Änderung im hier betrachteten Zeitintervall. Beispielsweise könnte ein Intervall mit annähernd gleichbleibenden gemessenen Distanzen vorausgehen und auch folgen. Die große Veränderung im hier betrachteten Zeitraum deutet darauf hin, daß der Sensor irgend etwas erfaßt hat, das eventuell von Bedeutung sein könnte.

Bei dem Beispiel in Abbildung 9 würde das Merkmalssymbol *increasing* zugewiesen. Als Basiswahrnehmungsmerkmal wird dann ausgegeben:

`increasing(t100,207,s0,1,8,19).`

3.2.1.2 Merkmalssymbole für Sonderfälle

Die Abgrenzung von Sonderfällen gegen die in Kapitel 3.2.1.1 aufgeführten erfolgt einerseits aufgrund einer etwas anderen Art der Bestimmung der Merkmale und andererseits aufgrund ihrer andersartigen und i. a. geringeren Aussagekraft. In diesen Fällen wird kein Winkel berechnet, sondern es wird ein Wert für den Winkel zugewiesen. Um diese zugewiesenen Winkel abzugrenzen gegen die berechneten, wurden Werte gewählt, bei denen sofort zu erkennen ist, daß sie nicht berechnet wurden.

Zu den Sonderfällen gehören Drehungen des Roboters. Drehungen um 360° und Vielfache davon werden nicht erkannt, da Drehungen nur anhand der geänderten Orientierung des Sensors oder des Roboters zu bestimmen sind. Beim Test auf Gleichheit zweier Sensororientierungen werden minimale Richtungsänderungen des Roboters durch Bodenunebenheiten ausgeglichen, indem Nachkommastellen nicht berücksichtigt und Schwankungen bis zu 3° toleriert werden. Es handelt sich hier um einen empirisch anhand der vorhandenen Meßdaten ermittelten Wert, der bei Bedarf auf einfache Art verändert werden kann.

- Der Fall, daß der Roboter zwischen zwei Messungen gefahren ist und sich währenddessen gedreht hat, läßt sich folgendermaßen algorithmisch fassen:

```
WENN (Abstand der Roboterpositionen zu den Zeitpunkten t-1 und t  $\neq$  0
      UND   Sensororientierung zum Zeitpunkt t-1 nicht gleich
           Sensororientierung zum Zeitpunkt t)

      DANN   setze Winkel auf -666
```

Aufeinanderfolgende Intervalle mit diesem Winkel werden zusammengefaßt zu einem größeren Intervall, dem das Merkmalssymbol *illegal_movement* zugewiesen wird.

Das Merkmalssymbol drückt aus, daß diese Art der Bewegung dem Roboter eigentlich verboten ist, da Wahrnehmungen während dieser Bewegung sehr schwer zu interpretieren sind. Sollte dieser Fall dennoch vorkommen, wird er daher zum Lernen der abstrakteren Begriffe nicht verwendet.

Das zweite Argument eines Basiswahrnehmungsmerkmals (siehe Abbildung 7 in Kapitel 3.1) ist die Orientierung des Sensors während des Zeitintervalls. Diese Orientierung wird im folgenden als **Intervall-Orientierung** bezeichnet. Als Intervall-Orientierung wird stets die Orientierung des Sensors zu Beginn des Zeitintervalls gewählt. Im Fall einer Drehung ändert sich die Orientierung während des Zeitintervalls, so daß die Intervall-Orientierung in diesem Fall nicht die Sensororientierung bei allen Messungen des Zeitraumes repräsentiert. Eine Alternative wäre, bei jeder Änderung der Sensororientierung ein neues Zeitintervall zu beginnen. Das hätte zur Folge, daß zahlreiche Basiswahrnehmungsmerkmale mit dem gleichen Merkmalssymbol und einem sehr kurzen Zeitintervall aneinandergereiht würden. Die zweite Alternative wäre, den Mittelwert der Sensororientierungen zu berechnen. Da jedoch dieses Basiswahrnehmungsmerkmal für das Lernen

abstrakterer Begriffe irrelevant ist und die erste Alternative zudem recht eigentümlich anmutende Ausgaben produzieren würde, wird die einfachste Art der Auswahl einer Intervall-Orientierung auch hier angewendet.

- Der Fall, daß sich der Roboter zwischen zwei Messungen gedreht hat ohne zu fahren, läßt sich folgendermaßen algorithmisch fassen:

WENN (Abstand der Roboterpositionen zu den Zeitpunkten t-1 und t = 0
UND Sensororientierung zum Zeitpunkt t-1 nicht gleich
Sensororientierung zum Zeitpunkt t)

DANN setze Winkel auf 666

Aufeinanderfolgende Intervalle mit diesem Winkel werden zusammengefaßt zu einem größeren Intervall, dem das Merkmalssymbol *rotation* zugewiesen wird.

In diesem Fall gibt es einen mathematischen Grund dafür, warum kein Winkel berechnet wird: der zurückgelegte Weg a beträgt 0 (vgl. mit der Formel zur Berechnung des Winkels α in Kapitel 3.2.1.1).

Die Bemerkungen zur Auswahl einer Intervall-Orientierung im Fall des Merkmalssymbols *illegal_movement* gelten auch hier.

- Der Fall, daß mindestens eine der beiden aufeinanderfolgenden Messungen erfolglos war, der Roboter gefahren ist und sich nicht gedreht hat, läßt sich folgendermaßen algorithmisch fassen:

WENN (Abstand der Roboterpositionen zu den Zeitpunkten t-1 und t \neq 0
UND Sensororientierung zum Zeitpunkt t-1 gleich
Sensororientierung zum Zeitpunkt t
UND (gemessene Distanz zum Zeitpunkt t-1 = -1
ODER gemessene Distanz zum Zeitpunkt t = -1))

DANN setze Winkel auf 999

Aufeinanderfolgende Intervalle mit diesem Winkel werden zusammengefaßt zu einem größeren Intervall, dem das Merkmalssymbol *no_measurement* z u g e w i e s e n w i r d . Die Information, daß in einer bestimmten Richtung kein Objekt erfaßt wurde, ist für die Navigation wichtig, denn damit ist eine Bewegung in diese Richtung bei der Suche - etwa nach einer Tür - uninteressant. Dieses Merkmalssymbol ist also annähernd so aussagekräftig wie die Merkmalssymbole für Normalfälle, die Informationen über die Bewegung des Sensors relativ zum angemessenen Objekt beinhalten.

Würde im Fall zweier erfolgloser Messungen der Winkel α berechnet wie in Kapitel 3.2.1.1 angegeben, wäre das Ergebnis 0. Allein anhand dieses Winkels könnten zwei erfolglose Messungen also nicht von dem Fall unterschieden werden, daß die beiden Messungen erfolgreich waren und die gemessenen Distanzen übereinstimmten. Diese Unterscheidung ist jedoch aufgrund des völlig anderen Informationsgehaltes nötig. Ebenso würde die

Berechnung des Winkels α bei nur einer erfolglosen Messung völlig falsche Informationen liefern, da in die Differenz der beiden gemessenen Distanzen der fiktive Wert -1 einginge (vgl. mit Kapitel 3.1.1).

- Der Fall, daß sich der Roboter zwischen zwei Messungen nicht bewegt hat, läßt sich folgendermaßen algorithmisch fassen:

WENN (Abstand der Roboterpositionen zu den Zeitpunkten $t-1$ und $t = 0$
UND Sensororientierung zum Zeitpunkt $t-1$ gleich
Sensororientierung zum Zeitpunkt t)

DANN setze Winkel auf 777

Aufeinanderfolgende Intervalle mit diesem Winkel werden zusammengefaßt zu einem größeren Intervall, dem das Merkmalssymbol *no_movement* zugewiesen wird. Wie beim Sonderfall *rotation* darf auch hier kein Winkel berechnet werden, da $a = 0$ gilt.

Wenn sich der Roboter nicht bewegt hat, ist es unerheblich, ob er in diesem Zeitraum etwas gemessen hat, denn Erfolg oder Mißerfolg der Messungen dieses Zeitraumes wird in den benachbarten Zeitintervallen repräsentiert. Entweder waren sämtliche Messungen dieses Zeitraumes erfolglos, dann handelt es sich bei den benachbarten Zeitintervallen um *no_measurement*-Intervalle (siehe in Kapitel 3.2.2.1 die Fälle III.a.3 und III.c.4 links). Oder es wurde im gesamten Zeitraum die gleiche Distanz gemessen, dann wird diese gemessene Distanz ebenfalls in den benachbarten Zeitintervallen berücksichtigt²³. Diesen Zeitintervallen wird nämlich entweder ein Merkmalssymbol für einen Normalfall zugewiesen (siehe in Kapitel 3.2.2.1 die Fälle III.d.5 links und III.d.3) oder es handelt sich wieder um einen Sonderfall. Letztere Situation wird direkt anschließend beschrieben.

- Eine einzelne erfolgreiche Messung
 - eingerahmt von zwei der obigen Sonderfälle

sollte gesondert berücksichtigt werden, da sie sich in den beiden benachbarten Intervallen nicht wiederfindet.

Im Gegensatz dazu wird eine erfolgreiche Messung an der Grenze eines „Normalfall-Intervalls“ zu einem der obigen Sonderfälle bereits im erstgenannten Intervall berücksichtigt. Zur Anschauung sei auf Kapitel 3.2.2.1, Fall III.b.3 und III.b.4, verwiesen.

Aus dem gleichen Grund sollte auch eine einzelne erfolgreiche Messung

- am Anfang des Trace und gefolgt von einem der Sonderfälle außer *no_movement*

23 Durch die Ungenauigkeiten bei Ultraschallmessungen kann es vorkommen, daß nur annähernd gleiche Distanzen gemessen werden. Dann werden die zum Anfangs- bzw. Endzeitpunkt des *no_movement*-Intervalls gemessenen Distanzen im jeweils angrenzenden Zeitintervall berücksichtigt.

und

- am Ende des Trace, wobei einer der Sonderfälle außer *no_movement* vorausgeht

gesondert berücksichtigt werden. Der Sonderfall *no_movement* wird ausgeschlossen, da die Messung andernfalls zweimal berücksichtigt würde: das erste Mal am Anfang des *no_movement*-Intervalls (= Anfang des Trace) und das zweite Mal am Ende des *no_movement*-Intervalls, wenn ein weiterer Sonderfall bzw. ein Normalfall folgt. Die Begründung für das Trace-Ende läuft analog: sowohl bei einem vorausgehenden Sonderfall wie auch bei einem vorausgehenden Normalfall wurde die Messung bereits dort berücksichtigt.

Der Winkel wird im Fall dieser einzelnen Messung auf 888 gesetzt. Zugewiesen wird dem Intervall, das nur diese eine Messung enthält, das Merkmalsymbol *single_peak*.

Es sei noch angemerkt, daß die Bezeichnungen „Normalfall“ und „Sonderfall“ sich nicht auf die Häufigkeit des Auftretens dieser Fälle beziehen. Die hier vorgestellten Sonderfälle stellen also keineswegs Ausnahmen dar. Will man den Anteil an Normal- und Sonderfällen in einem Trace bestimmen, betrachtet man die Zeiträume, denen ein Merkmalsymbol für einen Normalfall zugewiesen wurde, und diejenigen, denen ein Merkmalsymbol für einen Sonderfall zugewiesen wurde. Bei den zur Verfügung stehenden Traces liegen beide Anteile durchschnittlich bei 50%. Für die einzelnen Traces ergeben sich jedoch sehr unterschiedliche Werte. Beispielsweise gibt es einen Trace mit einem Anteil von 71% Normalfällen und nur 29% Sonderfällen. Ebenso gibt es auch einen Trace mit nur 36% Normalfällen aber 64% Sonderfällen.

Die Bezeichnung „Normalfall“ soll ausdrücken, daß es sich gerade um die interessanten Fälle handelt. Das gilt insbesondere, wenn mehrere aufeinanderfolgende Winkel berechnet werden wie in Kapitel 3.2.1.1 angegeben. Kapitel 3.2.2.2 geht auf diese Situation ein.

3.2.2 Der Algorithmus

Wie bereits erwähnt ist das Ziel der Verarbeitung, jeweils für einen Trace und einen Sensor die Sensordaten in Zeitintervallen zusammenzufassen. Für jeden Meßzeitpunkt t muß entschieden werden, ob das aktuelle Intervall bei $t-1$ bzw. bei t beendet oder aber fortgesetzt wird. Für die Fälle, die in Kapitel 3.2.2.1 beschrieben werden, sind folgende Informationen für diese Entscheidung nötig:

- der Datensatz des Zeitpunktes $t-1$
- der Datensatz des Zeitpunktes t

und

- der Intervall-Winkel

Diese Daten müssen also jeweils aktualisiert und gespeichert werden. Zudem müssen der Anfangszeitpunkt und die Intervall-Orientierung gespeichert werden

bis entschieden wird, das Intervall zu beenden. Für die eigentlich interessanten Fälle, die dann in Kapitel 3.2.2.2 beschrieben werden, sind weitere Informationen erforderlich, z.B. die Anzahl der Winkel im Zeitintervall, die ebenfalls aktualisiert und gespeichert werden müssen.

Im allgemeinen wird für die Entscheidung, ob das aktuelle Zeitintervall fortgesetzt wird, nur ein Teil der bekannten Daten benötigt. Nach der Verarbeitung des aktuellen Datensatzes werden aber stets alle potentiell relevanten Daten gespeichert.

Bei der folgenden Beschreibung des Algorithmus wird jeweils angegeben,

- welche Werte bekannt sind,
- welche Werte für die Entscheidung, wie der aktuelle Datensatz verarbeitet wird, relevant sind

und

- welche Werte gespeichert werden.

3.2.2.1 Fallunterscheidung für jeden Datensatz

Bei der Verarbeitung der Sensordaten von Zeitpunkt t (hier ist sowohl eine erfolgreiche wie auch eine erfolglose Messung gemeint) sind diverse Fälle zu unterscheiden, die in diesem Kapitel systematisch aufgezählt werden unter Berücksichtigung der Möglichkeiten des Zusammenfassens mehrerer Fälle für die Implementierung.

In den Skizzen werden folgende Symbole verwendet:








	Der Roboter ist gefahren und hat sich dabei nicht gedreht.
	Der Roboter ist gefahren und hat sich dabei gedreht.
	Der Roboter hat sich gedreht ohne zu fahren.
	Der Roboter hat sich nicht bewegt.
	Zum Zeitpunkt t fand eine erfolgreiche Messung statt.
	Zum Zeitpunkt t fand eine erfolglose Messung statt.
	Zum Zeitpunkt $t-1$ wurde der Trace beendet.

Abb. 10: Legende

Wenn im folgenden von einem **berechneten Winkel** die Rede ist, bedeutet das, daß ein Winkel gemäß der in Kapitel 3.2.1.1 angegebenen Formel bestimmt wurde. Es handelt sich also um einen Normalfall. Mit einem **zugewiesenen Winkel** ist dagegen einer der in Kapitel 3.2.1.2 genannten Sonderfälle gemeint.

Außerdem sei noch einmal betont, daß jeweils für die Messung zum Zeitpunkt t entschieden wird, ob das aktuelle Zeitintervall beendet oder fortgesetzt wird. Zu diesem Zeitpunkt ist die Verarbeitung der Messungen bis zum Zeitpunkt $t-1$ einschließlich bereits abgeschlossen.


Die zu unterscheidenden Situationen sind eingeteilt wie folgt:

- I Trace-Anfang; verarbeitet werden die ersten beiden Datensätze
- II der zu verarbeitende Datensatz markiert das Trace-Ende
- III alle übrigen Fälle

I Trace-Anfang

Bekannt sind jeweils die Datensätze von Zeitpunkt 1 und 2.

Fälle I.1




Relevant für die Verarbeitung sind:

- Zeitpunkt der vorherigen Messung = 1
- vorherige gemessene Distanz = -1
- aktuelle gemessene Distanz = -1

Das Intervall wird fortgesetzt, gespeichert werden die Daten:

- Intervall-Orientierung := Orientierung des Sensors zum Zeitpunkt 1
- Anfangszeitpunkt := 1
- Intervall-Winkel := zugewiesener Winkel (in der links dargestellten Situation)
bzw. berechneter Winkel (in der rechts dargestellten Situation)
- Anzahl der Winkel := 1

Fall I.2




Relevant für die Verarbeitung sind:

- Zeitpunkt der vorherigen Messung = 1
- vorherige gemessene Distanz = -1
- aktuelle gemessene Distanz \neq -1 und \neq -2
- zugewiesener Winkel = 666 oder -666

Das Intervall wird fortgesetzt; gespeichert werden die Daten:

- Intervall-Orientierung := Orientierung des Sensors zum Zeitpunkt 1
- Anfangszeitpunkt := 1
- Intervall-Winkel := zugewiesener Winkel
- Anzahl der Winkel := 1

Fälle I.3



Relevant für die Verarbeitung sind:

- Zeitpunkt der vorherigen Messung = 1
- vorherige gemessene Distanz \neq -1
- aktuelle gemessene Distanz = -1

Gemäß Kapitel 3.2.1.2, Sonderfall *single_peak*, ergibt sich, daß die erste Messung gesondert zu berücksichtigen ist. Ihr wird ebenfalls ein Winkel zugewiesen, nämlich 888.


Ausgegeben werden für dieses Intervall mit der einzelnen Messung die Werte:

- Intervall-Orientierung := Orientierung des Sensors zum Zeitpunkt 1
- Anfangszeitpunkt := 1
- Endzeitpunkt := 1
- Intervall-Winkel := zugewiesener Winkel für die einzelne Messung

Bei Zeitpunkt 1 beginnt außerdem ein neues Intervall, das fortgesetzt wird. Gespeichert werden dafür die Daten:

- Intervall-Orientierung
- Anfangszeitpunkt
- Intervall-Winkel := zugewiesener Winkel für die Messungen zum Zeitpunkt 1
und 2 (in der links dargestellten Situation) bzw.
berechneter Winkel (in der rechts dargestellten Situation)
- Anzahl der Winkel := 1

Fall I.4



Relevant für die Verarbeitung sind:

- Zeitpunkt der vorherigen Messung = 1
- vorherige gemessene Distanz $\neq -1$
- aktuelle gemessene Distanz $\neq -1$ und $\neq -2$
- zugewiesener Winkel für die Messungen zum Zeitpunkt 1 und 2 = 666 oder -666

Gemäß Kapitel 3.2.1.2, Sonderfall *single_peak*, ergibt sich, daß die erste Messung gesondert zu berücksichtigen ist. Ihr wird der Winkel 888 zugewiesen.

Ausgegeben werden für dieses Intervall mit der einzelnen Messung die Werte:


- Intervall-Orientierung := Orientierung des Sensors zum Zeitpunkt 1

- Anfangszeitpunkt := 1
- Endzeitpunkt := 1
- Intervall-Winkel := zugewiesener Winkel für die einzelne Messung

Bei Zeitpunkt 1 beginnt außerdem ein neues Intervall, das fortgesetzt wird.
Gespeichert werden dafür die Daten:

- Intervall-Orientierung
- Anfangszeitpunkt
- Intervall-Winkel := zugewiesener Winkel für die Messungen zum Zeitpunkt 1 und 2
- Anzahl der Winkel := 1

Fall I.5



Relevant für die Verarbeitung sind:

- Zeitpunkt der vorherigen Messung = 1
- vorherige gemessene Distanz = -1
- aktuelle gemessene Distanz $\neq -1$ und $\neq -2$
- zugewiesener Winkel = 999


Das Intervall wird beendet, ausgegeben werden die Werte:

- Intervall-Orientierung := Orientierung des Sensors zum Zeitpunkt 1
- Anfangszeitpunkt := 1
- Endzeitpunkt := 2
- Intervall-Winkel := zugewiesener Winkel

Gespeichert werden die Daten:

- Intervall-Orientierung
- Anfangszeitpunkt := 2
- Anzahl der Winkel := 0

Fälle I.6




Relevant für die Verarbeitung sind:

- Zeitpunkt der vorherigen Messung = 1
- aktuelle gemessene Distanz $\neq -1$ und $\neq -2$
- berechneter Winkel (in der links dargestellten Situation)
bzw. zugewiesener Winkel = 777 (in der rechts dargestellten Situation)

Das Intervall wird fortgesetzt; gespeichert werden die Daten:

- Intervall-Orientierung := Orientierung des Sensors zum Zeitpunkt 1
- Anfangszeitpunkt := 1
- Intervall-Winkel := berechneter bzw. zugewiesener Winkel
- Anzahl der Winkel := 1

Fall I.7



Relevant für die Verarbeitung sind:


- Zeitpunkt der vorherigen Messung = 1
- vorherige gemessene Distanz = -1
- aktuelle gemessene Distanz = -2

In diesem Fall gibt es also lediglich eine erfolglose Messung. Die Verarbeitung der Sensordaten für den aktuellen Trace und den Sensor wird beendet; der Winkel 999 wird zugewiesen. Ausgegeben werden die Werte:

- Intervall-Orientierung := Orientierung des Sensors zum Zeitpunkt 1
- Anfangszeitpunkt := 1
- Endzeitpunkt := 1
- Intervall-Winkel := zugewiesener Winkel

Es entsteht also ein Basiswahrnehmungsmerkmal mit dem Merkmalssymbol *no-measurement* für den einzigen Meßzeitpunkt.

Fall I.8



Relevant für die Verarbeitung sind:

- Zeitpunkt der vorherigen Messung = 1
- vorherige gemessene Distanz \neq -1
- aktuelle gemessene Distanz = -2

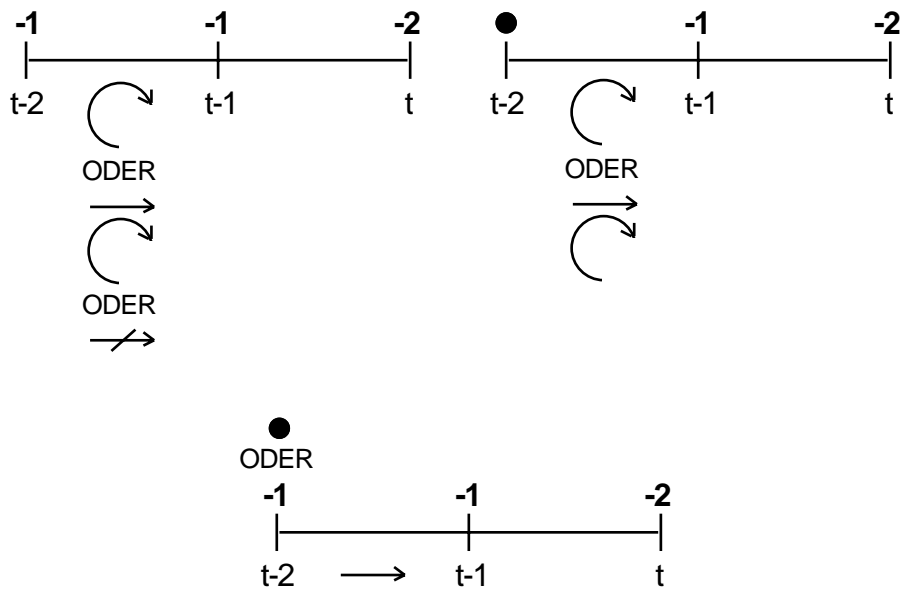
Nur die einzelne Messung ist zu berücksichtigen. Die Verarbeitung der Sensordaten für den aktuellen Trace und den Sensor ist damit beendet; ausgegeben werden die Werte:

- Intervall-Orientierung := Orientierung des Sensors zum Zeitpunkt 1
- Anfangszeitpunkt := 1
- Endzeitpunkt := 1
- Intervall-Winkel := 888

II Trace-Ende

Bekannt sind jeweils die Datensätze von Zeitpunkt $t-1$ und t , der Anfangszeitpunkt des aktuellen Intervalls, die Anzahl der Winkel im Intervall und die Intervall-Orientierung. Falls bereits ein Intervall-Winkel berechnet wurde, ist auch er bekannt.

Fälle II.1




Relevant für die Verarbeitung sind:

- vorherige gemessene Distanz = -1
- aktuelle gemessene Distanz = -2
- Intervall-Winkel = 666 oder -666 oder 777 oder 999

Es wird weder ein Winkel berechnet noch ein Winkel zugewiesen. Das aktuelle Intervall und die Verarbeitung der Sensordaten für den aktuellen Trace und den Sensor werden beendet; ausgegeben werden die Werte:

- Intervall-Orientierung
- Anfangszeitpunkt
- Endzeitpunkt := $t-1$
- Intervall-Winkel

Fälle II.2



Relevant für die Verarbeitung sind:

- vorherige gemessene Distanz $\neq -1$
- aktuelle gemessene Distanz = -2
- Intervall-Winkel = 666 oder -666 oder 777

Es wird weder ein Winkel berechnet noch ein Winkel zugewiesen. Das aktuelle Intervall wird beendet, die letzte Messung wird gemäß Kapitel 3.2.1.2, Sonderfall *single_peak*, berücksichtigt, und die Verarbeitung der Sensordaten für den aktuellen Trace und den Sensor wird beendet.


Ausgegeben werden für das aktuelle Intervall die Werte:

- Intervall-Orientierung
- Anfangszeitpunkt
- Endzeitpunkt := t-1
- Intervall-Winkel

Für das Intervall mit der einzelnen Messung wird ausgegeben:

- Intervall-Orientierung := Orientierung des Sensors zum Zeitpunkt t-1
- Anfangszeitpunkt := t-1
- Endzeitpunkt := t-1
- Intervall-Winkel := 888

Fall II.3



Relevant für die Verarbeitung sind:


- vorherige gemessene Distanz $\neq -1$
- aktuelle gemessene Distanz = -2
- Anzahl der Winkel = 0

Die letzte Messung wird berücksichtigt und die Verarbeitung der Sensordaten für den aktuellen Trace und den Sensor wird beendet.

Ausgegeben werden für das aktuelle Intervall mit der einzelnen Messung die Werte:

- Intervall-Orientierung
- Anfangszeitpunkt
- Endzeitpunkt := t-1
- Intervall-Winkel := 888

Fall II.4



Relevant für die Verarbeitung sind:

- vorherige gemessene Distanz $\neq -1$
- aktuelle gemessene Distanz = -2
- Intervall-Winkel $\neq 666$ und $\neq -666$ (Der Intervall-Winkel ist also entweder ein berechneter Winkel oder der zugewiesene Winkel 777.)

Das aktuelle Intervall und die Verarbeitung der Sensordaten für den aktuellen Trace und den Sensor werden beendet; ausgegeben werden die Werte:

- Intervall-Orientierung
- Anfangszeitpunkt
- Endzeitpunkt := t-1
- Intervall-Winkel

III alle übrigen Fälle

Hier wird, wie bisher, danach differenziert, ob die Messungen zu den beiden betrachteten Zeitpunkten erfolgreich waren oder nicht. Um die zahlreichen Fälle abzugrenzen, wird diese Differenzierung zusätzlich durch folgende Überschriften verdeutlicht:

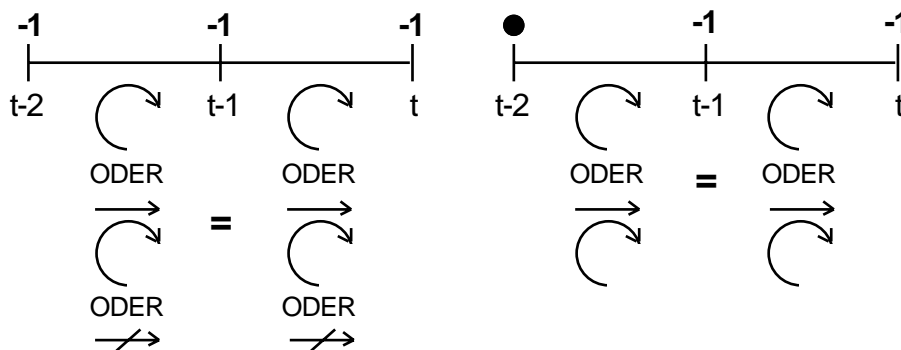
- III.a zwei erfolglose Messungen
- III.b eine erfolgreiche Messung gefolgt von einer erfolglosen Messung
- III.c eine erfolglose Messung gefolgt von einer erfolgreichen Messung
- III.d zwei erfolgreiche Messungen

Für die Implementierung ist eine weitere Zusammenfassung von Fällen aus unterschiedlichen dieser vier Gruppen möglich, was aus Gründen der Übersichtlichkeit erst am Schluß des Abschnitts III dargestellt wird.

Bekannt sind jeweils die Datensätze von Zeitpunkt $t-1$ und t , der Anfangszeitpunkt des aktuellen Intervalls, die Anzahl der Winkel im Intervall und die Intervall-Orientierung. Falls bereits ein Intervall-Winkel berechnet wurde, ist auch er bekannt.

III.a zwei erfolglose Messungen

Fälle III.a.1



Relevant für die Verarbeitung sind:

- vorherige gemessene Distanz = -1
- aktuelle gemessene Distanz = -1
- Intervall-Winkel = 666 oder -666 oder 777
- zugewiesener Winkel = 666 oder -666 oder 777
- Intervall-Winkel = zugewiesener Winkel


Das Intervall wird fortgesetzt; gespeichert werden die Daten:

- Intervall-Orientierung

- Anfangszeitpunkt
- Intervall-Winkel
- Anzahl der Winkel

Obwohl ein weiterer Winkel in das aktuelle Intervall aufgenommen wurde, wird die Anzahl der Winkel nicht um 1 erhöht. Die Anzahl der Winkel, die 1 überschreitet, ist nur dann relevant, wenn es sich beim Intervall-Winkel nicht um einen der Sonderfälle handelt (siehe Kapitel 3.2.2.2). Bei den Sonderfällen ist lediglich die Differenzierung zwischen einer Anzahl von 0 und einer Anzahl von 1 notwendig. Als Beispiel siehe Fall III.b.3 und III.b.4.

Fälle III.a.2



Relevant für die Verarbeitung sind:

- vorherige gemessene Distanz = -1
- aktuelle gemessene Distanz = -1
- Intervall-Winkel = 666 oder -666 oder 777
- zugewiesener Winkel = 666 oder -666 oder 777
- Intervall-Winkel \neq zugewiesener Winkel

Das aktuelle Intervall wird beendet; ausgegeben werden die Werte:


- Intervall-Orientierung
- Anfangszeitpunkt
- Endzeitpunkt := $t-1$
- Intervall-Winkel

Gespeichert werden die Daten des nächsten Intervalls:

- Intervall-Orientierung := Orientierung des Sensors zum Zeitpunkt $t-1$
- Anfangszeitpunkt := $t-1$

- Intervall-Winkel := zugewiesener Winkel
- Anzahl der Winkel := 1

Fall III.a.3



Relevant für die Verarbeitung sind:

- vorherige gemessene Distanz = -1
- aktuelle gemessene Distanz = -1
- Intervall-Winkel = 999
- zugewiesener Winkel = 666 oder -666 oder 777


Das aktuelle Intervall wird beendet; ausgegeben werden die Werte:

- Intervall-Orientierung
- Anfangszeitpunkt
- Endzeitpunkt := t-1
- Intervall-Winkel

Gespeichert werden die Daten des nächsten Intervalls:

- Intervall-Orientierung
- Anfangszeitpunkt := t-1
- Intervall-Winkel := zugewiesener Winkel
- Anzahl der Winkel := 1

Fälle III.a.4



Relevant für die Verarbeitung sind:

- vorherige gemessene Distanz = -1
- aktuelle gemessene Distanz = -1
- Intervall-Winkel = 666 oder -666 oder 777
- zugewiesener Winkel = 999


Das aktuelle Intervall wird beendet; ausgegeben werden die Werte:

- Intervall-Orientierung
- Anfangszeitpunkt
- Endzeitpunkt := $t-1$
- Intervall-Winkel

Gespeichert werden die Daten des nächsten Intervalls:

- Intervall-Orientierung := Orientierung des Sensors zum Zeitpunkt $t-1$
- Anfangszeitpunkt := $t-1$
- Intervall-Winkel := zugewiesener Winkel
- Anzahl der Winkel := 1

Fall III.a.5



Relevant für die Verarbeitung sind:


- vorherige gemessene Distanz = -1
- aktuelle gemessene Distanz = -1
- Intervall-Winkel = 999
- zugewiesener Winkel = 999

Das Intervall wird fortgesetzt; gespeichert werden die Daten:

- Intervall-Orientierung
- Anfangszeitpunkt
- Intervall-Winkel
- Anzahl der Winkel

III.b eine erfolgreiche Messung gefolgt von einer erfolglosen Messung

Fall III.b.1



Relevant für die Verarbeitung sind:


- vorherige gemessene Distanz \neq -1
- aktuelle gemessene Distanz = -1
- Intervall-Winkel = 666 oder -666
- zugewiesener Winkel = 666 oder -666

- Intervall-Winkel = zugewiesener Winkel

Das Intervall wird fortgesetzt; gespeichert werden die Daten:

- Intervall-Orientierung
- Anfangszeitpunkt
- Intervall-Winkel
- Anzahl der Winkel

Fall III.b.2



Relevant für die Verarbeitung sind:

- vorherige gemessene Distanz $\neq -1$
- aktuelle gemessene Distanz = -1
- Intervall-Winkel = 666 oder -666 oder 777
- zugewiesener Winkel = 666 oder -666
- Intervall-Winkel \neq zugewiesener Winkel

Das aktuelle Intervall wird beendet. Ausgegeben werden die Werte:

- Intervall-Orientierung
- Anfangszeitpunkt
- Endzeitpunkt := $t-1$
- Intervall-Winkel

Gemäß Kapitel 3.2.1.2, Sonderfall *single_peak*, wird die einzelne Messung gesondert berücksichtigt. Für das Intervall mit der einzelnen Messung wird ausgegeben:


- Intervall-Orientierung := Orientierung des Sensors zum Zeitpunkt $t-1$
- Anfangszeitpunkt := $t-1$
- Endzeitpunkt := $t-1$

- Intervall-Winkel := 888

Außerdem beginnt bei t-1 ein neues Intervall. Gespeichert werden dafür folgende Daten:

- Intervall-Orientierung := Orientierung des Sensors zum Zeitpunkt t-1
- Anfangszeitpunkt := t-1
- Intervall-Winkel := zugewiesener Winkel
- Anzahl der Winkel := 1

Fall III.b.3



Relevant für die Verarbeitung sind:

- vorherige gemessene Distanz $\neq -1$
- aktuelle gemessene Distanz = -1
- Anzahl der Winkel = 0
- zugewiesener Winkel = 666 oder -666

Das Zeitintervall mit dem Winkel 999 wurde bereits bei der Verarbeitung der Messung von Zeitpunkt t-1 beendet (siehe Fall III.c.4 und III.c.5). Diese einzelne Messung wird jetzt gemäß Kapitel 3.2.1.2, Sonderfall *single_peak*, berücksichtigt.

Ausgegeben werden für das aktuelle Intervall mit der einzelnen Messung die Werte:


- Intervall-Orientierung
- Anfangszeitpunkt
- Endzeitpunkt := t-1
- Intervall-Winkel := 888

Gespeichert werden die Daten des nächsten Intervalls:

- Intervall-Orientierung
- Anfangszeitpunkt := t-1
- Intervall-Winkel := zugewiesener Winkel

- Anzahl der Winkel := 1

Fall III.b.4



Relevant für die Verarbeitung sind:

- vorherige gemessene Distanz $\neq -1$
- aktuelle gemessene Distanz = -1
- Intervall-Winkel $\neq 666$ und $\neq -666$ und $\neq 777$

(Natürlich ist der Intervall-Winkel ein berechneter Winkel. Genau das wird bei der Implementierung mit der hier angegebenen Bedingung überprüft, sie schließt nämlich alle möglichen zugewiesenen Winkel aus. Der einzige weitere Sonderfall, Intervall-Winkel = 999, wurde soeben bei Fall III.b.3 behandelt.)

- zugewiesener Winkel = 666 oder -666


Das aktuelle Intervall wird beendet, ausgegeben werden die Werte:

- Intervall-Orientierung
- Anfangszeitpunkt
- Endzeitpunkt := $t-1$
- Intervall-Winkel

Gespeichert werden die Daten des nächsten Intervalls:

- Intervall-Orientierung
- Anfangszeitpunkt := $t-1$
- Intervall-Winkel := zugewiesener Winkel
- Anzahl der Winkel := 1

Fälle III.b.5



Relevant für die Verarbeitung sind:

- aktuelle gemessene Distanz = -1
- vorherige gemessene Distanz \neq -1
- Intervall-Winkel = 666 oder -666 oder 777
- zugewiesener Winkel = 999

Das aktuelle Intervall wird beendet. Ausgegeben werden die Werte:

- Intervall-Orientierung
- Anfangszeitpunkt
- Endzeitpunkt := t-1
- Intervall-Winkel


Gemäß Kapitel 3.2.1.2, Sonderfall *single_peak*, wird außerdem die einzelne Messung berücksichtigt. Für das Intervall, das nur diese Messung enthält, wird ausgegeben:

- Intervall-Orientierung := Orientierung des Sensors zum Zeitpunkt t-1
- Anfangszeitpunkt := t-1
- Endzeitpunkt := t-1
- Intervall-Winkel := 888

Außerdem beginnt bei t-1 ein neues Intervall. Gespeichert werden dafür folgende Daten:

- Intervall-Orientierung := Orientierung des Sensors zum Zeitpunkt t-1
- Anfangszeitpunkt := t-1
- Intervall-Winkel := zugewiesener Winkel
- Anzahl der Winkel := 1

Fall III.b.6



Relevant für die Verarbeitung sind:

- vorherige gemessene Distanz $\neq -1$
- aktuelle gemessene Distanz = -1
- Anzahl der Winkel = 0
- zugewiesener Winkel = 999


Das Zeitintervall mit dem Winkel 999 wurde bereits bei der Verarbeitung der Messung von Zeitpunkt $t-1$ beendet (siehe Fall III.c.4 und III.c.5). Diese einzelne Messung wird jetzt gemäß Kapitel 3.2.1.2, Sonderfall *single_peak*, berücksichtigt. Ausgegeben werden für das aktuelle Intervall mit der einzelnen Messung:

- Intervall-Orientierung
- Anfangszeitpunkt
- Endzeitpunkt := $t-1$
- Intervall-Winkel := 888

Bei $t-1$ beginnt außerdem ein neues Intervall. Gespeichert werden dafür folgende Daten:

- Intervall-Orientierung
- Anfangszeitpunkt
- Intervall-Winkel := zugewiesener Winkel
- Anzahl der Winkel := 1

Fall III.b.7



Relevant für die Verarbeitung sind:

- vorherige gemessene Distanz $\neq -1$
- aktuelle gemessene Distanz = -1
- Intervall-Winkel $\neq 666$ und $\neq -666$ und $\neq 777$

(Natürlich ist auch hier der Intervall-Winkel ein berechneter Winkel. Genau das wird bei der Implementierung mit der hier angegebenen Bedingung überprüft, sie schließt nämlich alle möglichen zugewiesenen Winkel aus. Der einzige weitere Sonderfall wurde soeben bei Fall III.b.6 behandelt: es geht ein *no_measurement*-Intervall voraus.)

- zugewiesener Winkel = 999

Das aktuelle Intervall wird beendet; ausgegeben werden die Werte:

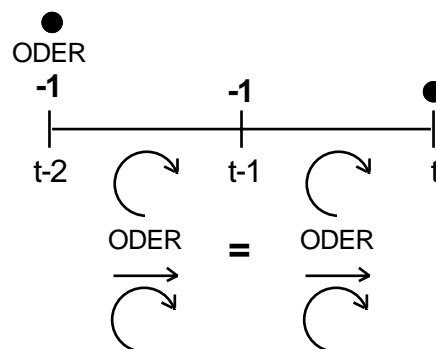
- Intervall-Orientierung
- Anfangszeitpunkt
- Endzeitpunkt := t-1
- Intervall-Winkel

Gespeichert werden die Daten des nächsten Intervalls:

- Intervall-Orientierung
- Anfangszeitpunkt := t-1
- Intervall-Winkel := zugewiesener Winkel
- Anzahl der Winkel := 1

III.c eine erfolglose Messung gefolgt von einer erfolgreichen Messung

Fall III.c.1




Relevant für die Verarbeitung sind:

- vorherige gemessene Distanz = -1
- aktuelle gemessene Distanz $\neq -1$ und $\neq -2$
- Intervall-Winkel = 666 oder -666
- zugewiesener Winkel = 666 oder -666
- Intervall-Winkel = zugewiesener Winkel

Das Intervall wird fortgesetzt; gespeichert werden die Daten:

- Intervall-Orientierung
- Anfangszeitpunkt
- Intervall-Winkel
- Anzahl der Winkel

Fälle III.c.2



Relevant für die Verarbeitung sind:

- vorherige gemessene Distanz = -1
- aktuelle gemessene Distanz \neq -1 und \neq -2
- Intervall-Winkel = 666 oder -666 oder 777
- zugewiesener Winkel = 666 oder -666
- Intervall-Winkel \neq zugewiesener Winkel


Das aktuelle Intervall wird beendet; ausgegeben werden die Werte:

- Intervall-Orientierung
- Anfangszeitpunkt
- Endzeitpunkt := t-1
- Intervall-Winkel

Gespeichert werden die Daten des nächsten Intervalls:

- Intervall-Orientierung := Orientierung des Sensors zum Zeitpunkt t-1
- Anfangszeitpunkt := t-1
- Intervall-Winkel := zugewiesener Winkel
- Anzahl der Winkel := 1

Fall III.c.3



Relevant für die Verarbeitung sind:

- vorherige gemessene Distanz = -1
- aktuelle gemessene Distanz $\neq -1$ und $\neq -2$
- Intervall-Winkel = 999
- zugewiesener Winkel = 666 oder -666


Das aktuelle Intervall wird beendet; ausgegeben werden die Werte:

- Intervall-Orientierung
- Anfangszeitpunkt
- Endzeitpunkt := $t-1$
- Intervall-Winkel

Gespeichert werden die Daten des nächsten Intervalls:

- Intervall-Orientierung
- Anfangszeitpunkt := $t-1$
- Intervall-Winkel := zugewiesener Winkel
- Anzahl der Winkel := 1

Fälle III.c.4



Relevant für die Verarbeitung sind:

- vorherige gemessene Distanz = -1
- aktuelle gemessene Distanz $\neq -1$ und $\neq -2$
- Intervall-Winkel = 666 oder -666 oder 777
- zugewiesener Winkel = 999

Das aktuelle Intervall wird beendet; ausgegeben werden die Werte:

- Intervall-Orientierung
- Anfangszeitpunkt
- Endzeitpunkt := t-1
- Intervall-Winkel


Das folgende Intervall wird ebenfalls beendet; ausgegeben werden die Werte:

- Intervall-Orientierung := Orientierung des Sensors zum Zeitpunkt t-1
- Anfangszeitpunkt := t-1
- Endzeitpunkt := t
- Intervall-Winkel := zugewiesener Winkel

Gespeichert werden die Daten des nächsten Intervalls:

- Intervall-Orientierung
- Anfangszeitpunkt := t
- Anzahl der Winkel := 0

Fall III.c.5



Relevant für die Verarbeitung sind:

- vorherige gemessene Distanz = -1
- aktuelle gemessene Distanz $\neq -1$ und $\neq -2$
- Intervall-Winkel = 999
- zugewiesener Winkel = 999

Das aktuelle Intervall wird beendet; ausgegeben werden die Werte:


- Intervall-Orientierung
- Anfangszeitpunkt
- Endzeitpunkt := t
- Intervall-Winkel

Gespeichert werden die Daten des nächsten Intervalls:

- Intervall-Orientierung
- Anfangszeitpunkt := t
- Anzahl der Winkel := 0

III.d zwei erfolgreiche Messungen

Fälle III.d.1




Relevant für die Verarbeitung sind:

- vorherige gemessene Distanz $\neq -1$
- aktuelle gemessene Distanz $\neq -1$ und $\neq -2$
- Intervall-Winkel = 666 oder -666 oder 777
- zugewiesener Winkel = 666 oder -666 oder 777
- Intervall-Winkel = zugewiesener Winkel

Das Intervall wird fortgesetzt; gespeichert werden die Daten:

- Intervall-Orientierung
- Anfangszeitpunkt
- Intervall-Winkel
- Anzahl der Winkel

Fälle III.d.2



Relevant für die Verarbeitung sind:

- vorherige gemessene Distanz = -1
- aktuelle gemessene Distanz \neq -1 und \neq -2
- Intervall-Winkel = 666 oder -666 oder 777
- zugewiesener Winkel = 666 oder -666 oder 777
- Intervall-Winkel \neq zugewiesener Winkel

Das aktuelle Intervall wird beendet. Ausgegeben werden für das aktuelle Intervall die Werte:

- Intervall-Orientierung
- Anfangszeitpunkt
- Endzeitpunkt := t-1
- Intervall-Winkel


Gemäß Kapitel 3.2.1.2, Sonderfall *single_peak*, wird die einzelne Messung gesondert berücksichtigt. Für das Intervall mit der einzelnen Messung wird ausgegeben:

- Intervall-Orientierung := Orientierung des Sensors zum Zeitpunkt t-1
- Anfangszeitpunkt := t-1
- Endzeitpunkt := t-1
- Intervall-Winkel := 888

Gespeichert werden die Daten des nächsten Intervalls:

- Intervall-Orientierung := Orientierung des Sensors zum Zeitpunkt t-1
- Anfangszeitpunkt := t-1
- Intervall-Winkel := zugewiesener Winkel
- Anzahl der Winkel := 1

Fall III.d.3



Relevant für die Verarbeitung sind:

- vorherige gemessene Distanz $\neq -1$
- aktuelle gemessene Distanz $\neq -1$ und $\neq -2$
- Intervall-Winkel $\neq 666$ und $\neq -666$ und $\neq 777$

(Auch hier ist der Intervall-Winkel ein berechneter Winkel. Vgl. mit den Fällen III.b.4 und III.b.7.)

- zugewiesener Winkel = 666 oder -666 oder 777


Das aktuelle Intervall wird beendet; ausgegeben werden die Werte:

- Intervall-Orientierung
- Anfangszeitpunkt
- Endzeitpunkt := t-1
- Intervall-Winkel

Gespeichert werden die Daten des nächsten Intervalls:

- Intervall-Orientierung
- Anfangszeitpunkt := t-1
- Intervall-Winkel := zugewiesener Winkel
- Anzahl der Winkel := 1

Fall III.d.4



Relevant für die Verarbeitung sind:

- vorherige gemessene Distanz $\neq -1$
- aktuelle gemessene Distanz $\neq -1$ und $\neq -2$
- Anzahl der Winkel = 0
- zugewiesener Winkel = 666 oder -666 oder 777

Das Zeitintervall mit dem Winkel 999 wurde bereits bei der Verarbeitung der Messung von Zeitpunkt $t-1$ beendet (siehe Fall III.c.4 und III.c.5). Diese einzelne Messung wird jetzt gemäß Kapitel 3.2.1.2, Sonderfall *single_peak*, berücksichtigt.


Ausgegeben werden für das aktuelle Intervall mit der einzelnen Messung die Werte:

- Intervall-Orientierung
- Anfangszeitpunkt
- Endzeitpunkt := $t-1$
- Intervall-Winkel := 888

Für das neue Intervall, das bei $t-1$ beginnt, werden folgende Daten gespeichert:

- Intervall-Orientierung
- Anfangszeitpunkt
- Intervall-Winkel := zugewiesener Winkel
- Anzahl der Winkel := 1

Fälle III.d.5



Relevant für die Verarbeitung sind:

- vorherige gemessene Distanz $\neq -1$
- aktuelle gemessene Distanz $\neq -1$ und $\neq -2$
- Intervall-Winkel = 666 oder -666 oder 777
- Es kann ein Winkel berechnet werden.

Das aktuelle Intervall wird beendet; ausgegeben werden die Werte:


- Intervall-Orientierung
- Anfangszeitpunkt
- Endzeitpunkt := $t-1$
- Intervall-Winkel

Gespeichert werden die Daten des nächsten Intervalls:

- Intervall-Orientierung := Orientierung des Sensors zum Zeitpunkt $t-1$
- Anfangszeitpunkt := $t-1$
- Intervall-Winkel := berechneter Winkel
- Anzahl der Winkel := 1
- Abweichung := 0

(Die Definition der Abweichung findet sich in Kapitel 3.2.2.2.)

Fall III.d.6




Relevant für die Verarbeitung sind:

- vorherige gemessene Distanz $\neq -1$
- aktuelle gemessene Distanz $\neq -1$ und $\neq -2$
- Anzahl der Winkel = 0
- Es kann ein Winkel berechnet werden.

Das aktuelle Intervall wird fortgesetzt; gespeichert werden die Werte:

- Intervall-Orientierung
- Anfangszeitpunkt
- Intervall-Winkel := berechneter Winkel
- Anzahl der Winkel := 1
- Abweichung := 0

Der einzige bislang noch nicht betrachtete Fall ist gerade der interessante: zwei Normalfälle in Folge.



Dieser Fall wird in Kapitel 3.2.2.2 behandelt.

Nachgetragen seien noch die bereits angekündigten weiteren Möglichkeiten der Zusammenfassung einzelner Fälle. Über die Grenzen der Einteilung nach dem Erfolg der beiden betrachteten Messungen hinweg lassen sich nämlich für die Implementierung einige Fälle aus Abschnitt III noch weiter zusammenfassen.

(1) Fälle III.b.2 und Fälle III.d.2

Relevant für die Verarbeitung sind:

- vorherige gemessene Distanz $\neq -1$
- aktuelle gemessene Distanz $\neq -2$

- Intervall-Winkel = 666 oder -666 oder 777
- zugewiesener Winkel = 666 oder -666 oder 777
- Intervall-Winkel \neq zugewiesener Winkel

Das aktuelle Intervall wird beendet. Ausgegeben werden die Werte:

- Intervall-Orientierung
- Anfangszeitpunkt
- Endzeitpunkt := t-1
- Intervall-Winkel

Die einzelne Messung wird gesondert berücksichtigt. Für das Intervall, das nur diese Messung enthält, wird ausgegeben:

- Intervall-Orientierung := Orientierung des Sensors zum Zeitpunkt t-1
- Anfangszeitpunkt := t-1
- Endzeitpunkt := t-1
- Intervall-Winkel := 888

Außerdem beginnt bei t-1 ein neues Intervall, das fortgesetzt wird. Gespeichert werden dafür die Daten:

- Intervall-Orientierung
- Anfangszeitpunkt
- Intervall-Winkel := zugewiesener Winkel
- Anzahl der Winkel := 1

(2) Fälle III.a.1, Fall III.a.5, Fall III.b.1, Fall III.c.1, Fälle III.d.1

Relevant für die Verarbeitung sind:

- aktuelle gemessene Distanz \neq -2
- Intervall-Winkel = 666 oder -666 oder 777 oder 999
- zugewiesener Winkel = 666 oder -666 oder 777 oder 999
- Intervall-Winkel = zugewiesener Winkel

Das aktuelle Intervall wird fortgesetzt; gespeichert werden die Werte:

- Intervall-Orientierung
- Anfangszeitpunkt
- Intervall-Winkel

- Anzahl der Winkel


Für sämtliche übrigen Fälle aus den Abschnitten I bis III gilt, daß man sie nicht weiter zusammenfassen kann, ohne durch die disjunktive Verknüpfung der einzelnen Bedingungen auch Fälle abzudecken, bei denen eine andere Art der Verarbeitung erfolgen muß.

3.2.2.2 Beeinflußbare Kriterien für das Beenden eines Zeitintervalls

Mit diesem Kapitel nähern wir uns nun dem spannenden Teil des hier vorgestellten Verfahrens.

Neben den Kriterien gemessene Distanzen, Intervall-Winkel und zugewiesener bzw. berechneter Winkel gibt es weitere, die einen großen Einfluß haben auf die bei der Verarbeitung der Sensordaten entstehenden Sequenzen von Basiswahrnehmungsmerkmalen. Zum Tragen kommen sie in der folgenden Situation:

Fall III.d.7



Relevant für die Verarbeitung sind:

- vorherige gemessene Distanz $\neq -1$
- aktuelle gemessene Distanz $\neq -1$ und $\neq -2$
- Intervall-Winkel $\neq 666$ und $\neq -666$ und $\neq 777$

(Auch hier ist der Intervall-Winkel ein berechneter Winkel. Vgl. mit den Fällen III.b.4, III.b.7 und III.d.3.)

- Es kann ein Winkel berechnet werden.

Die Kriterien geben an, bis zu welchen Grenzen der berechnete Winkel noch als den im Intervall enthaltenen Winkeln²⁴ ähnlich angesehen werden kann. Unterschieden wird zwischen drei sogenannten Verfahrensparametern und ein bis drei Parametern, für die jeweils verschiedene Werte angegeben werden können.

24 Bisher wurde gesprochen vom Zusammenfassen von Meßzeitpunkten auf der Basis von Winkeln, die zwei aufeinanderfolgenden Messungen zugewiesen bzw. aus ihnen berechnet wurden. Vereinfachend ist jetzt vom Zusammenfassen von Winkeln die Rede, womit aber immer noch der gleiche Vorgang gemeint ist.

Die Kombination der maximal sechs erlaubten Werte legt dann das Verfahren zur Generierung der Basiswahrnehmungsmerkmale fest. Diese Kombination wird im folgenden als **Parametersatz** bezeichnet.

Es folgt eine Beschreibung der Verfahrensparameter und der Parameter jeweils mit der Angabe, welche Werte erlaubt sind.

Der erste Verfahrensparameter regelt, wie der Intervall-Winkel bestimmt wird.

Verfahrensparameter A

- Der Wert A1 bewirkt, daß der erste Winkel eines Zeitintervalls als Intervall-Winkel beibehalten wird.
- Der Wert A2 bewirkt, daß der Intervall-Winkel als Mittelwert aller bisher im Intervall vorhandenen Winkel berechnet wird.

Der Mittelwert MW_{neu} kann inkrementell berechnet werden:

$$MW_{\text{neu}} = \frac{MW_{\text{alt}} * (\text{AnzWinkel} - 1) + \text{Winkel}}{\text{AnzWinkel}}$$

mit Winkel = aktueller Winkel, für den entschieden wird, ob er noch zum aktuellen Intervall gehört

MW_{alt} = alter Mittelwert, also Intervall-Winkel vor Hinzufügen des aktuellen Winkels

AnzWinkel = Anzahl der Winkel im Intervall nach Hinzufügen des aktuellen Winkels

Die Beantwortung der Frage, ob der berechnete Winkel den bereits im Intervall enthaltenen Winkeln ähnlich ist und folglich dem Intervall hinzugefügt wird, erfolgt anhand des Vergleichs mit dem Intervall-Winkel. Bestimmt wird die Differenz zwischen dem Intervall-Winkel und dem berechneten Winkel.²⁵

Die beiden Werte für **Verfahrensparameter B** regeln die Einzelheiten:

- Der Wert B1 bewirkt, daß die Differenz als konstanter Wert berechnet wird.
- Der Wert B2 bewirkt, daß die Differenz als proportionaler Wert (in %) berechnet wird.

25 Denkbar wäre auch, die Differenz zwischen dem aktuellen Intervall-Winkel und dem Intervall-Winkel zu bestimmen, der entsteht, wenn man den Winkel hinzufügt. Dagegen spricht aber, daß, um das Intervall zu beenden, sich der Winkel bei A2 umso mehr unterscheiden muß vom Intervall-Winkel, je größer die Länge des Intervalls ist. Zudem macht die Berechnung dieser Differenz bei A1 natürlich keinen Sinn.

Der zugehörige **Parameter B** gibt an, wie groß die maximal erlaubte Differenz ist, bis zu der der berechnete Winkel noch als „ähnlich“ eingestuft wird. Mögliche Werte für diesen Parameter sind positive, reelle Zahlen. Vom Wert für Verfahrensparameter B hängt ab, ob der Wert für Parameter B als konstanter oder proportionaler Wert interpretiert wird.

Verfahrensparameter C legt fest, ob als zusätzliches Kriterium die Abweichung der Winkel im Intervall vom Intervall-Winkel herangezogen wird.

Die Abweichung wird hier definiert als

$$AW_{\text{neu}} = \frac{AW_{\text{alt}} * (\text{AnzWinkel} - 1) + |\text{Int-Winkel} - \text{Winkel}|}{\text{AnzWinkel}}$$

- mit AW_{alt} = durchschnittliche Abweichung der Winkel im Intervall vom alten Intervall-Winkel vor Hinzufügen des aktuellen Winkels
- Winkel = aktueller Winkel, für den entschieden wird, ob er noch zum aktuellen Intervall gehört
- Int-Winkel = Intervall-Winkel nach Hinzufügen des aktuellen Winkels
- AnzWinkel = Anzahl der Winkel im Intervall nach Hinzufügen des aktuellen Winkels (Die Abweichung wird nur berechnet, wenn die Anzahl der Winkel im Intervall mindestens 2 beträgt.)

Es handelt sich also bei Kombination mit A1 um eine durchschnittliche absolute Differenz der Winkel zum jeweiligen Intervall-Winkel. Bei Kombination mit A2 wird diese durchschnittliche Differenz nur angenähert, denn bei jedem Schritt wird der jeweilige aktuelle Intervall-Winkel verwendet, der sich bei der Berechnung des Mittelwertes aller Winkel im Intervall im allgemeinen vom vorherigen Intervall-Winkel unterscheidet.

Die Standardabweichung

$$\sqrt{\frac{\sum_{i=1}^{\text{AnzWinkel}} (\text{Winkel}_i - \text{Intervall-Winkel})^2}{\text{AnzWinkel}}}$$

findet keine Verwendung, da sie nicht inkrementell berechnet werden kann.

Für Verfahrensparameter C gibt es drei mögliche Werte:

- Bei C0 wird die Abweichung der Winkel im Intervall vom Intervall-Winkel nicht berücksichtigt.

- Bei C1 wird diese Abweichung berücksichtigt.
- Bei C2 wird diese Abweichung berücksichtigt, und es wird unterschieden zwischen alternierenden und nicht-alternierenden Folgen berechneter Winkel.

Zu Verfahrensparameter C gehört je nach Wert eine unterschiedliche Anzahl von Parametern. Die Werte für diese Parameter sind positive, reelle Zahlen, die die maximal erlaubte Abweichung in Grad angeben. Bei C1 wird nur ein Parameter benötigt, bei C2 sind es zwei. Der Gleichmäßigkeit alternierender Folgen von Winkeln wird mit einer größeren erlaubten Abweichung Rechnung getragen. Für die maximal erlaubte Abweichung bei alternierenden Folgen wird daher ein größerer Wert gewählt als für die maximal erlaubte Abweichung bei nicht-alternierenden Folgen.

Das Verfahren bei C1:

Für den aktuellen berechneten Winkel, für den zu entscheiden ist, ob er dem Intervall hinzugefügt werden kann, wird die Abweichung gemäß der Formel für AW_{neu} berechnet. Überschreitet die Abweichung die maximal erlaubte Abweichung, wird der Winkel dem Intervall nicht hinzugefügt, d.h. das Intervall wird bei Zeitpunkt $t-1$ beendet. Wird die maximal erlaubte Abweichung dagegen nicht überschritten, kann der Winkel hinzugefügt werden, d.h. das Intervall wird fortgesetzt.

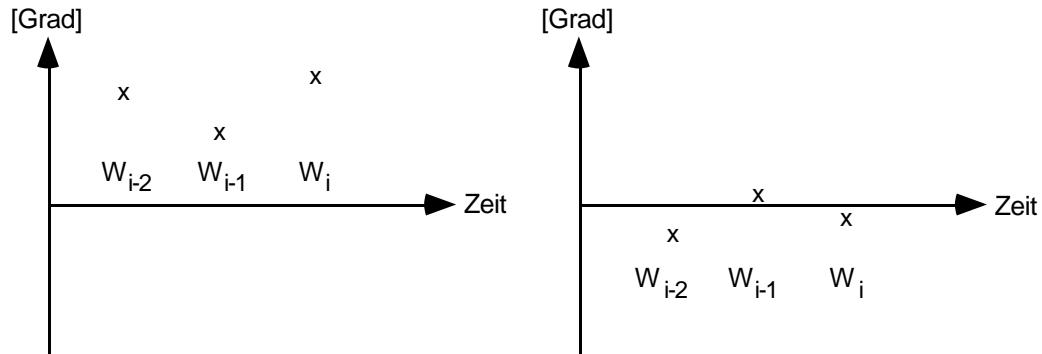
Das Verfahren bei C2:

Der Parameter für C1, der die maximal erlaubte Abweichung angibt, wird auch hier benutzt, gibt jedoch bei C2 die maximal erlaubte Abweichung für nicht-alternierende Folgen an. Der zweite Parameter gibt die maximal erlaubte Abweichung für alternierende Folgen vor.

Als alternierend werden Folgen von Winkeln W_i definiert, für die gilt:

- 1) Die Folge enthält mindestens 3 Winkel.
- 2) Für jeweils drei aufeinanderfolgende Winkel W_{i-2} , W_{i-1} und W_i der Folge gilt:
 $W_i > W_{i-1}$, falls $W_{i-1} < W_{i-2}$
 $W_i < W_{i-1}$, falls $W_{i-1} > W_{i-2}$
- 2) Die maximal erlaubte Abweichung für alternierende Folgen wird nicht überschritten.


Punkt 2 gibt das Verhältnis der Winkel an. Die folgenden Skizzen zeigen Beispiele für Folgen dreier Winkel, die diese Bedingungen erfüllen.



Zu beachten ist, daß hier durch ein Kreuz im Koordinatensystem nicht eine zu einem Zeitpunkt gemessene Distanz dargestellt wird, sondern ein Winkel, der jeweils für die Messungen zweier aufeinanderfolgender Zeitpunkte berechnet wurde.

Bei Berücksichtigung von alternierenden Folgen gemäß obiger Definition ist die Verarbeitung der Sensordaten nicht mehr streng inkrementell, da nicht direkt nach dem Einlesen eines Datensatzes entschieden werden kann, ob das Intervall beendet oder fortgesetzt wird, sondern erst bei Vorliegen dreier Winkel. Die Verzögerung der Reaktion auf die entsprechende Wahrnehmung und der Aufwand für das Speichern zweier Winkel sind jedoch so gering, daß man dieses Vorgehen tolerieren kann, falls durch diese Art der Verarbeitung der Sensordaten geeignete Sequenzen von Basiswahrnehmungs-merkmalen generiert werden.

Im folgenden (Fälle III.d.7.a und III.d.7.b) wird zunächst die hier skizzierte Situation betrachtet:



Ein Zeitintervall beginnt bei t-2. Es wurden bisher zwei Winkel W_1 und W_2 berechnet. Dann kann i. a. lediglich eine These darüber aufgestellt werden, um welche Art von Folge es sich handelt. Diese These wird sich nach Berechnung des dritten Winkels entweder bewahrheiten oder aber sie wird eingeschränkt oder widerlegt. Dabei ist zusätzlich das Verhältnis des Winkels W_1 zum Winkel W_2 - also „gleich“, „kleiner“ oder „größer“ - zu berücksichtigen, das demnach gespeichert werden muß.

Relevant für die These, um welche Art von Folge es sich handelt, sind:

- W_1 := Winkel, der für die beiden Messungen bei t-2 und t-1 berechnet wurde = Intervall-Winkel
- W_2 := Winkel, der für die beiden Messungen bei t-1 und t berechnet wurde
- die Abweichung der beiden Winkel vom Intervall-Winkel
- die maximal erlaubte Abweichung bei nicht-alternierenden Folgen
- die maximal erlaubte Abweichung bei alternierenden Folgen

Fälle III.d.7.a

WENN ($W_1 < W_2$)

UND

die berechnete Abweichung überschreitet zwar die maximal erlaubte Abweichung für nicht-alternierende Folgen, aber nicht die maximal erlaubte Abweichung für alternierende Folgen)

DANN These := alternierende Folge,

Verhältnis von W_1 zu W_2 := „kleiner“

WENN ($W_1 < W_2$)

UND

die berechnete Abweichung überschreitet die maximal erlaubte Abweichung für nicht-alternierende Folgen nicht)

DANN These := alternierende oder nicht-alternierende Folge

Verhältnis von W_1 zu W_2 := „kleiner“

WENN ($W_1 > W_2$)

UND

die berechnete Abweichung überschreitet zwar die maximal erlaubte Abweichung für nicht-alternierende Folgen, aber nicht die maximal erlaubte Abweichung für alternierende Folgen)

DANN These := alternierende Folge,

Verhältnis von W_1 zu W_2 := „größer“

WENN ($W_1 > W_2$)

UND

die berechnete Abweichung überschreitet die maximal erlaubte Abweichung für nicht-alternierende Folgen nicht)

DANN These := alternierende oder nicht-alternierende Folge

Verhältnis von W_1 zu W_2 := „größer“

Im folgenden Fall reichen zwei berechnete Winkel aus, um mit Sicherheit eine alternierende Folge von Winkeln ausschließen zu können.

WENN ($W_1 = W_2$)

UND

die berechnete Abweichung überschreitet die maximal erlaubte Abweichung für nicht-alternierende Folgen nicht)

DANN handelt es sich um eine nicht-alternierende Folge

Das Verhältnis der Winkel ist für nicht-alternierende Folgen irrelevant und wird daher nicht gespeichert.

In den Fällen III.d.7.a wird das Intervall vorläufig fortgesetzt. Gespeichert werden die Daten des aktuellen Intervalls:

- Intervall-Orientierung
- Anfangszeitpunkt
- neuer Intervall-Winkel

Er entspricht bei A1 dem alten Intervall-Winkel, also W_1 , während bei A2 der Mittelwert aus W_1 und W_2 berechnet wird.

- Anzahl der Winkel + 1
- neue Abweichung

Außerdem werden die Daten gespeichert, die bei der Verarbeitung der nächsten Messung evtl. benötigt werden, um endgültig zu entscheiden, ob die Folge fortgesetzt wird:


- die These bzw. die Angabe, um welche Art von Folge es sich handelt
- das Verhältnis von W_1 zu W_2
- W_1 und W_2

Der Winkel W_2 wird benötigt, um nach der Berechnung des dritten Winkels, W_3 , das Verhältnis zwischen W_2 und W_3 ermitteln zu können. Der Winkel W_1 muß gespeichert werden für den Fall, daß sich nach der Berechnung von W_3 herausstellt, daß das Intervall bereits bei Zeitpunkt t-1 beendet werden muß (siehe die Fälle III.d.7.d ²⁶).

26 Der jetzige Zeitpunkt t-1 entspricht dort dem Zeitpunkt t-2. Bei den Fällen III.d.7.d wird dann also vom Beenden des Intervalls zum Zeitpunkt t-2 die Rede sein.

Fälle III.d.7.b

In den übrigen Fällen überschreitet die berechnete Abweichung die maximal erlaubte Abweichung für alternierende Folgen, und das Intervall wird beendet.




Ausgegeben werden die Werte:

- Intervall-Orientierung
- Anfangszeitpunkt
- Endzeitpunkt := $t-1$
- Intervall-Winkel (= W_1)

Bei $t-1$ beginnt dann ein neues Intervall. Gespeichert werden dafür die folgenden Daten:

- Intervall-Orientierung
- Anfangszeitpunkt := $t-1$
- Intervall-Winkel := W_2
- Anzahl der Winkel := 1
- Abweichung := 0

Als nächstes werden die Fälle III.d.7.c und III.d.7.d betrachtet. Es wurden bereits drei Winkel berechnet, so daß in den meisten Fällen eine endgültige Entscheidung getroffen werden kann, welche Art von Folge vorliegt.



Die Fälle, in denen bereits mehr als drei Winkel berechnet wurden, werden genauso behandelt. Die Skizzen zeigen der Einfachheit halber jeweils nur die Situation für drei Winkel.


Relevant für die Entscheidung sind:

- W_2 = Winkel, der für die beiden Messungen bei t-2 und t-1 berechnet wurde
- W_3 := Winkel, der für die beiden Messungen bei t-1 und t berechnet wurde
- das Verhältnis von W_1 zu W_2
- die These bzw. die Angabe, um welche Art von Folge es sich handelt
- die Abweichung der drei Winkel vom Intervall-Winkel
- die maximal erlaubte Abweichung bei nicht-alternierenden Folgen
- die maximal erlaubte Abweichung bei alternierenden Folgen

Bekannt ist ausserdem W_1 , also der Winkel, der für die beiden Messungen bei t-3 und t-2 berechnet wurde.

Fälle III.d.7.c


Diese Fälle werden unterteilt gemäß der bisherigen These bzw. Angabe über die Art der Folge. Bei der Verarbeitung der aktuellen Messung t wird überprüft, ob die These bzw. Angabe noch gilt. Den einzelnen Fällen ist jeweils eine Skizze vorangestellt, die das Verhältnis der drei Winkel zueinander zeigt.



Bei dieser Skizze gilt beispielsweise:

Als Verhältnis von W_1 zu W_2 wurde „kleiner“ gespeichert, und es gilt $W_2 > W_3$.

These: alternierende Folge



WENN $(W_2 > W_3)$

UND

Verhältnis von W_1 zu $W_2 =$ „kleiner“

UND


These = alternierende Folge

UND

die berechnete Abweichung überschreitet die maximal erlaubte Abweichung für alternierende Folgen nicht)

DANN handelt es sich um eine alternierende Folge,

Verhältnis von W_2 zu $W_3 :=$ „größer“



WENN $(W_2 < W_3)$

UND

Verhältnis von W_1 zu $W_2 =$ „größer“

UND

These = alternierende Folge

UND

die berechnete Abweichung überschreitet die maximal erlaubte Abweichung für alternierende Folgen nicht)

DANN handelt es sich um eine alternierende Folge,

Verhältnis von W_2 zu $W_3 :=$ „kleiner“

These: alternierende oder nicht-alternierende Folge


In der folgenden Situation kann immer noch keine endgültige Entscheidung getroffen werden.

$$\begin{array}{ccc} & x & \\ x & & x \\ W_1 & W_2 & W_3 \end{array}$$

WENN $(W_2 > W_3$
UND
Verhältnis von W_1 zu $W_2 =$ „kleiner“
UND
These = alternierende oder nicht-alternierende Folge
UND
die berechnete Abweichung überschreitet die maximal erlaubte Abweichung für nicht-alternierende Folgen nicht)
DANN wurde die These bestätigt,
Verhältnis von W_2 zu $W_3 :=$ „größer“


$$\begin{array}{ccc} & x & \\ x & & x \\ W_1 & W_2 & W_3 \end{array}$$

WENN $(W_2 > W_3$
UND
Verhältnis von W_1 zu $W_2 =$ „kleiner“
UND
These = alternierende oder nicht-alternierende Folge
UND
die berechnete Abweichung überschreitet zwar die maximal erlaubte Abweichung für nicht-alternierende Folgen, nicht aber die maximal erlaubte Abweichung für alternierende Folgen)
DANN handelt es sich um eine alternierende Folge,
Verhältnis von W_2 zu $W_3 :=$ „größer“




WENN $(W_2 \leq W_3$
 UND
 Verhältnis von W_1 zu $W_2 =$ „kleiner“
 UND
 These = alternierende oder nicht-alternierende Folge
 UND
 die berechnete Abweichung überschreitet die maximal erlaubte
 Abweichung für nicht-alternierende Folgen nicht)
 DANN handelt es sich um eine nicht-alternierende Folge
 Das Verhältnis der Winkel ist für nicht-alternierende Folgen
 irrelevant und wird daher nicht gespeichert.

In der folgenden Situation kann ebenfalls noch keine endgültige Entscheidung
 getroffen werden.



WENN $(W_2 < W_3$
 UND
 Verhältnis von W_1 zu $W_2 =$ „größer“
 UND
 These = alternierende oder nicht-alternierende Folge
 UND
 die berechnete Abweichung überschreitet die maximal erlaubte
 Abweichung für nicht-alternierende Folgen nicht)
 DANN wurde die These bestätigt,
 Verhältnis von W_2 zu $W_3 :=$ „kleiner“



WENN ($W_2 < W_3$)

UND

Verhältnis von W_1 zu W_2 = „größer“

UND


These = alternierende oder nicht-alternierende Folge

UND

die berechnete Abweichung überschreitet zwar die maximal erlaubte Abweichung für nicht-alternierende Folgen, nicht aber die maximal erlaubte Abweichung für alternierende Folgen)

DANN handelt es sich um eine alternierende Folge,

Verhältnis von W_2 zu W_3 := „kleiner“



WENN ($W_2 \geq W_3$)

UND

Verhältnis von W_1 zu W_2 = „größer“

UND

These = alternierende oder nicht-alternierende Folge

UND

die berechnete Abweichung überschreitet die maximal erlaubte Abweichung für nicht-alternierende Folgen nicht)

DANN handelt es sich um eine nicht-alternierende Folge

Das Verhältnis der Winkel ist für nicht-alternierende Folgen irrelevant und wird daher nicht gespeichert.

Im folgenden Fall ist das Verhältnis der drei Winkel zueinander irrelevant, da bereits nach der Berechnung von W_2 feststand, daß es sich um eine **nicht-alternierende Folge** von Winkeln handelt.

WENN (nicht-alternierende Folge
 UND
 die berechnete Abweichung überschreitet die maximal erlaubte Abweichung für nicht-alternierende Folgen nicht)
 DANN handelt es sich um eine nicht-alternierende Folge

In den Fällen III.d.7.c wird das Intervall fortgesetzt. Gespeichert werden die Daten des aktuellen Intervalls:

- Intervall-Orientierung
- Anfangszeitpunkt
- neuer Intervall-Winkel

Er entspricht bei A1 dem alten Intervall-Winkel, also W_1 , während bei A2 der Mittelwert aus W_1 und W_2 berechnet wird.


- Anzahl der Winkel + 1
- neue Abweichung

Außerdem werden die Daten gespeichert, die bei der Verarbeitung der nächsten Messung evtl. benötigt werden, um zu entscheiden, ob die Folge fortgesetzt wird:

- die Angabe bzw. die These, um welche Art von Folge es sich handelt
- das Verhältnis von W_2 zu W_3
- W_2 und W_3

Fälle III.d.7.d


Übrig bleiben, analog zu III.d.7.b, die Fälle, in denen die berechnete Abweichung für die Winkel W_1 bis W_3 die maximal erlaubte Abweichung für alternierende Folgen überschreitet. In diesen Fällen muß das Intervall bei t-2 beendet werden.



Ausgegeben werden die Werte:

- Intervall-Orientierung
- Anfangszeitpunkt
- Endzeitpunkt := $t-2$
- Intervall-Winkel := W_1

Als nächstes muß festgestellt werden, ob die Winkel W_2 und W_3 in ein gemeinsames Intervall ab $t-2$ gehören. Dazu wird geprüft, ob einer der unter III.d.7.a genannten Fälle zutrifft. Die betrachtete Situation läßt sich folgendermaßen skizzieren:



Der Unterschied zu den unter III.d.7.a beschriebenen Fällen besteht also lediglich darin, daß es sich nicht mehr um die Winkel W_1 und W_2 handelt, sondern um die Winkel W_2 und W_3 .

Sollte einer dieser Fälle zutreffen, wird das Intervall ab $t-2$ vorläufig fortgesetzt.


Gespeichert werden in diesem Fall die Daten des aktuellen Intervalls ab $t-2$:

- Intervall-Orientierung
- Anfangszeitpunkt := $t-2$
- neuer Intervall-Winkel
Er entspricht bei A1 dem alten Intervall-Winkel, also W_2 , während bei A2 der Mittelwert aus W_2 und W_3 berechnet wird.
- Anzahl der Winkel := 2
- Abweichung der Winkel W_2 und W_3 vom Intervall-Winkel

Für die endgültige Entscheidung, welche Art von Folge vorliegt, werden weitere Daten benötigt, die demnach ebenfalls gespeichert werden müssen.

- die These bzw. die Angabe, um welche Art von Folge es sich handelt
- das Verhältnis von W_2 zu W_3
- W_2 und W_3

Trifft jedoch keiner der Fälle III.d.7.a zu, dann überschreitet die berechnete Abweichung die maximal erlaubte Abweichung für alternierende Folgen (auch hier wieder analog zu III.d.7.b), und auch das Intervall ab t-2 wird beendet.



Ausgegeben werden die Werte:

- Intervall-Orientierung
- Anfangszeitpunkt := t-2
- Endzeitpunkt := t-1
- Intervall-Winkel := W_2

Bei t-1 beginnt dann ein neues Intervall, für das folgende Werte gespeichert werden:

- Intervall-Orientierung
- Anfangszeitpunkt := t-1
- Intervall-Winkel := W_3
- Anzahl der Winkel := 1
- Abweichung := 0

3.3 Test und Analyse des Verfahrens zur Generierung der Basiswahrnehmungsmerkmale

3.3.1 Ziel der Tests

In diesem Kapitel werden die Untersuchungen der Auswirkung der verschiedenen Parametersätze auf die Erzeugung von Basiswahrnehmungsmerkmalen beschrieben. Sie hatten zum Ziel, Anhaltspunkte für eine Strategie zum Lernen eines geeigneten Parametersatzes zu finden. Von Interesse ist, Parametersätze zu ordnen, so daß gezielt nach einem geeigneten Parametersatz für die Erzeugung der Basiswahrnehmungsmerkmale gesucht werden kann. Das heißt, es muß sichergestellt sein, daß die Wahl eines Parametersatzes, der bezüglich einer

Halbordnung²⁷ kleiner (oder größer - das hängt von der Definition ab) ist, entweder zur gleichen Sequenz von Basiswahrnehmungsmerkmalen führt oder zu einer besseren. Da das Ergebnis der Verarbeitung der Meßdaten wiederum Eingabe für einen weiteren Lernschritt ist (siehe Kapitel 1), muß die Qualität der Basiswahrnehmungsmerkmale an den Erfordernissen dieses nächsten Lernschrittes gemessen werden. Auf diesen Punkt geht Kapitel 3.3.2.1 näher ein.

Formal ist also zu definieren

- eine Halbordnung $R_1 \sum M_1 \times M_1$, wobei M_1 eine Menge von Parametersätzen ist,
- eine Halbordnung $R_2 \sum M_2 \times M_2$, wobei M_2 eine Menge von Sequenzen von Basiswahrnehmungsmerkmalen ist

und

- eine Abbildung f der geordneten Menge $(M_1; R_1)$ in die geordnete Menge $(M_2; R_2)$ mit der Eigenschaft

$$\forall x, y \in M_1: (x, y) \in R_1 \sim (f(x), f(y)) \in R_2$$

f wird definiert durch das Verfahren zur Generierung der Basiswahrnehmungsmerkmale.

Untersucht wurde für zwei Halbordnungen R_{21} und R_{22} , ob es eine geordnete Menge $(M_1; R_1)$ gibt, so daß f die geforderte Eigenschaft hat. Sowohl bei R_{21} als auch bei R_{22} wird als Kriterium für die Bewertung, wie gut eine Sequenz von Basiswahrnehmungsmerkmalen für das Lernen abstrakterer Begriffe geeignet ist, die Länge der Intervalle zugrundegelegt.

- 1) Die Halbordnung R_{21} wird definiert anhand der Übereinstimmung der Basiswahrnehmungsmerkmale mit den Sensormusterbeispielen (genaue Definition siehe Kapitel 3.3.2.1). Die Länge der Intervalle geht insofern in die Definition ein, als die Wahrscheinlichkeit für eine gute Übereinstimmung von Basiswahrnehmungsmerkmalen und Sensormusterbeispielen umso größer ist, je kleiner die erzeugten Intervalle bei den Merkmalen sind.

27 Die Begriffe Halbordnung, Ordnung und strenge Ordnung werden in der Literatur nicht einheitlich verwendet. Hier ist mit Halbordnung eine Relation $R \sum M \times M$ gemeint mit den Eigenschaften

Reflexivität: $\forall x \in M: (x, x) \in R$

Transitivität: $\forall x, y, z \in M: (x, y) \in R \wedge (y, z) \in R \sim (x, z) \in R$

Antisymmetrie: $\forall x, y \in M: (x, y) \in R \wedge (y, x) \in R \sim x = y$

Eine Ordnung ist dagegen eine Relation $R \sum M \times M$ mit den Eigenschaften

Transitivität $\forall x, y, z \in M: (x, y) \in R \wedge (y, z) \in R \sim (x, z) \in R$

Asymmetrie: $\forall x, y \in M: (x, y) \in R \sim (y, x) \notin R$

Außerdem wurde bei den Tests der Frage nachgegangen, ob es möglich ist, Sequenzen von Basiswahrnehmungsmerkmalen zu generieren, die gemäß der hier vorgegebenen Bewertung sehr gut geeignet sind für das Lernen der Sensormuster.

- 2) Die Halbordnung R_{22} wird definiert anhand einer systematischen Intervalleinteilung (genaue Definition siehe Kapitel 3.3.2.2).

Um die Menge M_1 der Parametersätze einschränken zu können, wurde außerdem folgendes überprüft:

- 3) Kann man bestimmte Parametersätze grundsätzlich als „zu speziell“ einstufen bezüglich des Feinheitsgrades der generierten Sequenzen von Basiswahrnehmungsmerkmalen, d. h. erzeugen diese Parametersätze immer Sequenzen sehr kleiner Intervalle?

3.3.2 Testverfahren

3.3.2.1 Algorithmus zur Bewertung der generierten Sequenzen von Basiswahrnehmungsmerkmalen

Bei der Bewertung der generierten Basiswahrnehmungsmerkmale wird ermittelt, inwieweit sie geeignet sind, um im nächsten Lernschritt Regeln für Sensormuster lernen zu können.

Sensormuster sind bestimmte Anordnungen von Kanten (siehe Kapitel 3.1). Ziel dieses nächsten Lernschrittes ist, solche Sensormuster durch eine Folge von Basiswahrnehmungsmerkmalen zu definieren. Dafür werden dem Lernverfahren RDT (siehe Kapitel 1) u. a. Sensormusterbeispiele, also Beispiele für die zu lernenden Muster, und Basiswahrnehmungsmerkmale vorgegeben.

Beispiele für ein bestimmtes Sensormuster geben an, welcher Sensor in welchem Zeitraum eine Folge von Kanten angemessen hat, deren Anordnung der Definition dieses Sensormusters entspricht. Bei der Generierung der Sensormusterbeispiele werden die Meßdaten einschließlich der Klassifikation, d.h. der Informationen über die angemessene Kante, verwendet. Diese Klassifikation ist, wie bereits erwähnt, während der Lernphase in den messungsfakten enthalten (siehe Kapitel 3.1, Abbildung 4). Sie kann jedoch für die Generierung der Basiswahrnehmungsmerkmale nicht verwendet werden, da die Klassifikation nur in der Lernphase zur Verfügung steht, Basiswahrnehmungsmerkmale dagegen auch in der Anwendungsphase generiert werden müssen.

Wenn die Klassifikation der Meßdaten auch nicht während der Generierung der Basiswahrnehmungsmerkmale benutzt werden kann, so kann sie in der Lernphase doch nach der Generierung eingesetzt werden, indem nämlich die generierten Basiswahrnehmungsmerkmale mit den Sensormusterbeispielen verglichen werden. Die Sensormusterbeispiele geben vor, in welchen Zeiträumen welche

Sensoren wichtige Dinge wahrgenommen haben. Für gute Basiswahrnehmungsmerkmale muß also gelten:

1. Kriterium:

- Die Zeitintervalle der Basiswahrnehmungsmerkmale für die betreffenden Sensoren sollten möglichst exakt übereinstimmen mit den Zeiträumen, die die Sensormusterbeispiele als wichtig vorgeben.

Bei der Bewertung der Basiswahrnehmungsmerkmale muß außerdem ein Kriterium beachtet werden, das notwendig ist, um beim Lernen der Sensormuster mehrere Basiswahrnehmungsmerkmale über die Zeitpunkte verketteten zu können. Die B-Learn II-MitarbeiterInnen Volker Klingspor und Anke Rieger verwenden dieses Kriterium in ihrem Verfahren zur Auswahl geeigneter Basiswahrnehmungsmerkmale für das Lernen mit RDT.

2. Kriterium:

- Anfangszeitpunkt des Basiswahrnehmungsmerkmals \geq Anfangszeitpunkt des Beispiels und Endzeitpunkt des Basiswahrnehmungsmerkmals \leq Endzeitpunkt des Beispiels

Faßt man beide Kriterien zusammen, so kann man als Voraussetzung für die Eignung von Basiswahrnehmungsmerkmalen zum Lernen der Sensormuster angeben²⁸:

- Das Zeitintervall eines Basiswahrnehmungsmerkmals oder das Gesamt-Zeitintervall, das von aufeinanderfolgenden Basiswahrnehmungsmerkmalen gebildet wird, sollte das Zeitintervall eines Sensormusterbeispiels möglichst gut aufspalten.

Für das Sensormusterbeispiel

s_convex(t203,s2,195,208,straight_towards)

wäre z. B. das Basiswahrnehmungsmerkmal

straight_away(t203,300,s2,195,208,40)

perfekt geeignet, da die Zeiträume von Sensormusterbeispiel und Basiswahrnehmungsmerkmal exakt übereinstimmen.

Ebenso wären auch die aufeinanderfolgenden Basiswahrnehmungsmerkmale

something_happened(t203,300,s2,195,196,19) und

straight_away(t203,300,s2,196,208,42)

perfekt geeignet, da sie das Zeitintervall des Sensormusterbeispiels genau aufspalten.

28 Es handelt sich lediglich um eine notwendige Voraussetzung. Was außerdem noch erfüllt sein muß, um „gute“ Regeln für Sensormuster lernen zu können, steht in Kapitel 4.1.

Nicht ganz so gut geeignet wären für das obige Sensormusterbeispiel hingegen das Basiswahrnehmungsmerkmal

straight_away(t203,300,s2,197,207,39)

oder die aufeinanderfolgenden Basiswahrnehmungsmerkmale

something_happened(t203,300,s2,195,196,19) und

straight_away(t203,300,s2,196,205,41),

da sie den Zeitraum des Sensormusterbeispiels nicht ganz abdecken.

Als völlig ungeeignet ist das Basiswahrnehmungsmerkmal

straight_away(t203,300,s2,191,208,37)

anzusehen, da es einen größeren Zeitraum abdeckt als das Sensormusterbeispiel.

Gleiches gilt für die aufeinanderfolgenden Basiswahrnehmungsmerkmale

something_happened(t203,300,s2,195,196,19) und

straight_away(t203,300,s2,196,211,43).

Wie wird nun die Charakterisierung guter Basiswahrnehmungsmerkmale in ein Verfahren zur Bewertung der generierten Basiswahrnehmungsmerkmale umgesetzt? Im Gegensatz zur Vorgehensweise bei der Vorbereitung des nächsten Lernschrittes, bei der für ein zu lernendes Sensormuster geeignete Basiswahrnehmungsmerkmale ausgewählt werden, wird hier für jedes Basiswahrnehmungsmerkmal ein passendes Sensormusterbeispiel gesucht.

Die Qualität einer Sequenz von Basiswahrnehmungsmerkmalen wird dann mit einer positiven reellen Zahl bewertet, die die **Übereinstimmung mit den Sensormusterbeispielen** in Prozent angibt. Die Übereinstimmung ist definiert als der Quotient

$$\frac{\text{Gesamtlänge der geeigneten Basiswahrnehmungsmerkmale}}{\text{Gesamtlänge der Beispiele}}$$

Die Gesamtlänge der geeigneten Basiswahrnehmungsmerkmale ist die Länge aller Basiswahrnehmungsmerkmale eines Trace, für die es ein Sensormusterbeispiel gibt, so daß das 2. Kriterium (s. o.) erfüllt ist. Die Gesamtlänge der Beispiele ist die Länge aller Beispiele für Sensormuster im Trace. In beiden Fällen werden Zeiträume gegebenenfalls mehrfach berücksichtigt, da sich Sensormuster überschneiden können.

Beispielsweise kann es Sensormuster

s_line(t90,s4,37,65,straight_towards),

s_line(t90,s4,73,88,straight_towards) und

s_jump(t90,s4,37,88,straight_towards)

geben, wobei die Zeiträume [37;65] und [69;88] dann zweimal berücksichtigt werden. Analog geht bei diesem Beispiel auch das Basiswahrnehmungsmerkmal

straight_to(t90,110,s4,37,63,-45)

mit dem Zeitraum [37;63] zweimal in die Gesamtlänge der geeigneten Basiswahrnehmungsmerkmale ein, da es für zwei Sensormusterbeispiele geeignet ist.

Eine Übereinstimmung von 100% bedeutet, daß für jedes Sensormusterbeispiel ein Basiswahrnehmungsmerkmal generiert wurde, dessen Zeitintervall genau mit dem Zeitintervall des Sensormusterbeispiels übereinstimmt. Bei einer Übereinstimmung von 50% trifft das für rund die Hälfte der Sensormusterbeispiele zu. Es sind i. a. nicht genau 50%, da nicht das Verhältnis der Anzahl der Basiswahrnehmungsmerkmale zur Anzahl der Sensormusterbeispiele bestimmt wird, sondern die Zeitintervalle betrachtet werden und nicht alle Basiswahrnehmungsmerkmale und Sensormusterbeispiele gleichgroße Zeiträume abdecken. Bei einer Übereinstimmung von 0% gibt es für keines der Sensormusterbeispiele ein passendes Basiswahrnehmungsmerkmal. Das bedeutet dann, daß keines der generierten Basiswahrnehmungsmerkmale zum Lernen der Sensormuster verwendet werden kann.

Auf der Grundlage dieser Bewertung wird die Halbordnung R_{21} definiert wie folgt:
eine Sequenz von Basiswahrnehmungsmerkmalen S_1 ist spezieller als eine Sequenz S_2 :1 die Übereinstimmung mit den Sensormusterbeispielen ist für S_1 größer als für S_2 .

3.3.2.2 Algorithmus zur Überprüfung der systematischen Intervalleinteilung

Das Verfahren prüft, ob sich die angegebenen Parametersätze ordnen lassen gemäß einer Halbordnung R_{22} „spezieller als oder gleich“. Es wird also nach einer Halbordnung R_1 auf bestimmten Parametersätzen gesucht, von der gefordert wird, daß f die in Kapitel 3.3.1 genannte Eigenschaft hat. Ergebnis der Überprüfung ist für je zwei Parametersätze eine der Bewertungen „spezieller als“, „gleich“, „genereller als“ oder „keine Beziehung“.

Die Halbordnung R_{22} ist iterativ definiert wie im folgenden angegeben.

Seien P_1 und P_2 die beiden Parametersätze,


$I_{P_1_1}$ bis $I_{P_1_k}$ seien die Zeitintervalle der Sequenz von Basiswahrnehmungsmerkmalen, die von P_1 für einen Sensor erzeugt wurden,

$I_{P_2_1}$ bis $I_{P_2_n}$ seien die Zeitintervalle der Sequenz von Basiswahrnehmungsmerkmalen, die von P_2 für einen Sensor erzeugt wurden.

- I) Für jeden der 24 Sensoren wird jeweils die Intervallsequenz $I_{P_1_1}$ bis $I_{P_1_k}$ mit der Intervallsequenz $I_{P_2_1}$ bis $I_{P_2_n}$ verglichen. Beginnend mit $i, j = 1$ werden in jedem Schritt die Endpunkte der beiden Intervalle $I_{P_1_i}$ und $I_{P_2_j}$ verglichen und mit einer der obigen Bewertungen versehen. Aus dieser Bewertung und der Bewertung des vorherigen Schrittes (initialisiert wird mit der neutralen Bewertung „gleich“) ergibt sich jeweils eine neue und schließlich die endgültige Bewertung für das Verhältnis von P_1 zu P_2 bei diesem Sensor.

Das Vorgehen im einzelnen: Wenn die beiden Endpunkte übereinstimmen, sind die Intervalle I_{P1_i} und I_{P2_j} gleich und die bisherige vorläufige Bewertung wird beibehalten. Stimmen sie nicht überein, wird für das kürzere Intervall ein passender Endzeitpunkt gesucht.²⁹

Sei etwa I_{P1_i} das kürzere Intervall (analog für I_{P2_j} als kürzeres Intervall), dann wird der nächste Endzeitpunkt, also des Intervalls $I_{P1_{i+1}}$ mit dem Endzeitpunkt des längeren Intervalls I_{P2_j} verglichen. Sind sie identisch³⁰, ist ein passender Endzeitpunkt gefunden, d. h. das Intervall I_{P2_j} wird bei der Generierung mit Parametersatz P1 aufgespalten in zwei Intervalle I_{P1_i} und $I_{P1_{i+1}}$.




Sind jedoch die Endpunkte von $I_{P1_{i+1}}$ und I_{P2_j} nicht identisch³¹ und der Endpunkt des erstgenannten Intervalls kleiner ist als der Endpunkt des letzteren Intervalls, wird weiter nach einem passenden Endpunkt gesucht. Die Suche wird abgebrochen, sobald der erstgenannte Endpunkt (bzw. einer seiner „Nachfolger“) größer ist als der zweitgenannte; in diesem Fall gibt es also keinen passenden Endzeitpunkt.

Sofern ein passender Endzeitpunkt gefunden wird und die bisherige vorläufige Bewertung ist „P1 spezieller als P2“ oder „gleich“, wird als neue

29 Der Algorithmus bietet zudem die Möglichkeit, für die geforderte Übereinstimmung der Intervallgrenzen eine natürliche Zahl als Toleranzwert T_1 vorzugeben. Beim Vergleich der beiden Endpunkte wird ihre Differenz betrachtet: Wenn die Differenz die von der Benutzerin vorgegebene Toleranz T_1 nicht überschreitet, werden die Intervalle I_{P1_i} und I_{P2_j} als gleich angesehen, andernfalls wird ein passender Endpunkt gesucht. Das oben bei der iterativen Definition der Halbordnung beschriebene Vorgehen ist der Spezialfall $T_1 = 0$. Bei einem höheren Toleranzwert geht die für die Halbordnung benötigte Transitivität verloren.

30 Entsprechend ist das Kriterium im allgemeinen Fall, daß die Toleranz T_1 nicht überschritten wird.



vorläufige Bewertung „P1 spezieller als P2“ gewählt und die nächsten beiden Intervalle $I_{P_{2j+1}}$ und $I_{P_{1i+1}}$ (bzw. das entsprechende nachfolgende Intervall, falls $I_{P_{2j}}$ aufgespalten ist in mehr als zwei Intervalle) werden betrachtet. Falls die vorherige vorläufige Bewertung „P1 genereller als P2“ ist, steht die endgültige Bewertung „keine Beziehung“ für den Sensor und die Parametersätze P1, P2 fest .

Wird kein passender Endzeitpunkt gefunden, steht ebenfalls die endgültige Bewertung „keine Beziehung“ fest.

Allgemein gilt, daß die Beziehungen „genereller“ und „spezieller“ stets zu „keine Beziehung“ zusammengefaßt werden, da sie sich widersprechen.

Ist die endgültige Bewertung für den Sensor und die beiden Parametersätze gefunden, werden die Intervallsequenzen des nächsten Sensors betrachtet.

- II) Die 24 Bewertungen für jeweils einen Sensor und zwei Parametersätze P1 und P2 werden zu einer Gesamtbewertung für diese beiden Parametersätze zusammengefaßt. Entscheidend ist, wieviele der Einzelbewertungen „gleich“, „spezieller“, „genereller“ und „keine Beziehung“ für das Verhältnis von P1 zu P2 insgesamt existieren.³²

Die Bewertung „P1 ist spezieller als P2“ wird zugewiesen, wenn

- die Anzahl der Einzelbewertungen „genereller“ und „keine Beziehung“ 0 beträgt³³
- und
- mindestens einmal „spezieller“ vorkommt.

Dual dazu wird die Bewertung „P1 ist genereller als P2“ zugewiesen, wenn

- die Anzahl der Einzelbewertungen „spezieller“ und „keine Beziehung“ 0 beträgt
- und
- mindestens einmal „genereller“ vorkommt.

Die Bewertung „P1 gleich P2“ wird zugewiesen, wenn

32 Auch dieser Prozeß kann von der Benutzerin durch Vorgabe eines Toleranzwertes T_2 beeinflusst werden. Er gibt vor, wieviele abweichende Bewertungen maximal vorkommen dürfen. T_2 muß ebenfalls auf 0 gesetzt werden, um die Transitivität zu erhalten. Bei der Definition der Halbordnung ist daher nur dieser Fall berücksichtigt.

33 Im allgemeinen Fall ist statt 0 maximal T_2 erlaubt, und zusätzlich wird gefordert, daß die Anzahl der Einzelbewertungen „spezieller“ sowohl größer ist als die von „genereller“ wie auch von „keine Beziehung“. Analog bei „P1 ist genereller als P2“.

- nur die Einzelbewertungen „gleich“ vorkommen³⁴.

34 Im allgemeinen Fall muß die Anzahl der Einzelbewertungen „gleich“ sowohl größer sein als die von „genereller“ und „spezieller“ wie auch von „keine Beziehung“ und sowohl die Häufigkeit von „genereller“ und „spezieller“ wie auch von „keine Beziehung“ darf T_2 nicht überschreiten.

Die Bewertung „keine Beziehung“ wird zugewiesen, wenn

- sowohl die Einzelbewertung „spezieller“ als auch die Einzelbewertung „genereller“ vorkommt

oder

- mindestens einmal die Einzelbewertung „keine Beziehung“ vorkommt³⁵.

Die iterative Definition der Halbordnung R_{22} ist damit abgeschlossen.

Das Sortierverfahren bildet im Anschluß an die Bewertung aller verschiedenen Paare von Parametersätzen sämtliche Ketten von Parametersätzen gemäß der Halbordnung „spezieller als oder gleich“ mit maximaler Länge.

35 Im allgemeinen Fall wird die Bewertung „keine Beziehung“ zugewiesen, wenn

- die Anzahl der Einzelbewertungen „spezieller“ mindestens so groß ist wie die von „genereller“ und die Häufigkeit von „genereller“ die Toleranz T_2 überschreitet

oder

- die Anzahl der Einzelbewertungen „genereller“ mindestens so groß ist wie die von „spezieller“ und die Häufigkeit von „spezieller“ die Toleranz T_2 überschreitet

oder

- die Häufigkeit von „keine Beziehung“ die Toleranz T_2 überschreitet.

3.3.2.3 Testdaten

Für die Tests wurden drei Traces ausgewählt. Trace 52 ist eine Fahrt schräg durch eine Tür in einer, im Vergleich zu den anderen Traces, starken Wand in den leeren Raum.




Abb. 11

Bei Trace 92 erfolgt die gleiche Fahrt durch eine Tür in einer Wand normaler Stärke hinein in einen Raum mit zwei Objekten.




Abb. 12

Trace 203 stellt eine längere Fahrt dar, bei der der Roboter an einem Punkt im Raum startet, zur nächsten Wand fährt und sich solange an einer Wand entlang bewegt, bis er bei der Vorbeifahrt an der Tür diese wahrnimmt. Daraufhin fährt er rückwärts bis zur Tür zurück, dreht sich in die richtige Position, um durch die Tür zu fahren, und verläßt den Raum.




Abb. 13

3.3.3 Testergebnisse

Jede Tabelle stellt die Ergebnisse für eine Reihe systematisch zusammengefaßter Parametersätze für jeden Trace gegenüber. In den Spalten 2, 4 und 6 finden sich die Werte für die Übereinstimmung der vom jeweiligen Parametersatz für den jeweiligen Trace erzeugten Sequenz von Basiswahrnehmungsmerkmalen mit den Sensormusterbeispielen. Die Spalten 3, 5 und 7 enthalten Angaben darüber, welche Parametersätze Element der in Kapitel 3.3.2.2 definierten Halbordnung sind. Die vom dort beschriebenen Algorithmus gebildeten Ketten von Parametersätzen sind jeweils mit einem Kleinbuchstaben bezeichnet. Für die Parametersätze einer Kette gilt, daß sie sich halbordnen lassen. Diese Parametersätze einer Kette sind wiederum durchnummeriert, wobei der speziellste Parametersatz den kleinsten Index erhält. Identische Sequenzen von Basiswahrnehmungsmerkmalen sind durch einen zweifachen Rahmen gekennzeichnet.

Tabelle 1:

Als Intervall-Winkel wurde der erste Winkel beibehalten (A1), für die maximal erlaubte Differenz wurde ein konstanter Wert angegeben (B1), und die Abweichung wurde nicht berücksichtigt (C0). Der konstante Wert für die maximal erlaubte Differenz wurde variiert.

Parametersatz	Trace 52		Trace 92		Trace 203	
A1, B1, 10, C0	91,65%	a1	75,45%		97,52%	
A1, B1, 25, C0	82,86%		67,54%		92,67%	
A1, B1, 40, C0	79,48%	a2	67,75%		88,01%	

Tabelle2:

Als Intervall-Winkel wurde der erste Winkel beibehalten (A1), für die maximal erlaubte Differenz wurde ein konstanter Wert angegeben (B1), und zusätzlich fand die Abweichung Berücksichtigung (C1). Der konstante Wert für die maximal erlaubte Differenz wurde variiert (3. Parameter), und ebenso wurde die maximal erlaubte Abweichung variiert (5. Parameter).

Parametersatz	Trace 52		Trace 92		Trace 203	
A1, B1, 10, C1, 10	91,65%	a1	75,45%		97,52%	
A1, B1, 10, C1, 25						
A1, B1, 10, C1, 40						
A1, B1, 25, C1, 10	86,11%	b1, c1	69,1%		94,2%	
A1, B1, 25, C1, 25	82,86%		67,54%		92,67%	
A1, B1, 25, C1, 40						
A1, B1, 40, C1, 10	86,11%	c2	68,95%		90,77%	
A1, B1, 40, C1, 25	79,51%		67,63%		88,88%	
A1, B1, 40, C1, 40	79,48%	a2, b2, c3	67,75%		88,01%	

Die erlaubte Abweichung war bei einer maximal erlaubten Differenz von 10 irrelevant, erkennbar daran, daß identische Sequenzen von Basiswahrnehmungsmerkmalen generiert wurden (die natürlich auch mit den Sequenzen bei gleicher maximal erlaubter Differenz aus Tabelle 1 übereinstimmen), d.h. bei dieser geringen erlaubten Differenz führte stets sie zum Beenden eines Intervalls. Erst wenn größere Differenzen erlaubt sind, gewinnt die Abweichung an Bedeutung.

Tabelle 3:

Als Intervall-Winkel wurde der erste Winkel beibehalten (A1), für die maximal erlaubte Differenz wurde ein konstanter Wert angegeben (B1), und zusätzlich fand die Abweichung Berücksichtigung, wobei differenziert wurde zwischen alternierenden und nicht-alternierenden Folgen (C2). Der konstante Wert für die maximal erlaubte Differenz wurde variiert (3. Parameter) wie auch die maximal erlaubte Abweichung für nicht-alternierende Folgen (5. Parameter) und für alternierende Folgen (6. Parameter).

	Trace 52		Trace 92		Trace 203	
A1, B1, 10, C2, 10, 25	91,65%	a1	75,45%		97,52%	
A1, B1, 10, C2, 10, 40						
A1, B1, 10, C2, 25, 40						
A1, B1, 10, C2, 40, 55						
A1, B1, 25, C2, 10, 25	85,9%	b1	68,98%		94,12%	
A1, B1, 25, C2, 10, 40						
A1, B1, 25, C2, 25, 40	82,86%		67,54%		92,67%	
A1, B1, 25, C2, 40, 55						
A1, B1, 40, C2, 10, 25	85,87%	b2	68,89%		90,69%	c1
A1, B1, 40, C2, 10, 40					90,69%	c2
A1, B1, 40, C2, 25, 40	79,51%		67,63%		88,88%	
A1, B1, 40, C2, 40, 55	79,48%	a2	67,75%		88,01%	

Wie in Tabelle 2 zeigt sich auch hier das Verhältnis des Einflusses von maximal erlaubter Differenz und Abweichung.

Anzumerken ist, daß es sich bei den Ergebnissen für die Parametersätze A1,B1,40,C2,10,25 und A1,B1,40,C2,10,40 bei Trace 203 tatsächlich nicht um identische Sequenzen von Basiswahrnehmungsmerkmalen handelt, vielmehr wurde durch den ersten Parametersatz bei einem Sensor ein Intervall aufgespalten in zwei kleinere Intervalle. Da es für das große Intervall des zweiten Parametersatzes ein passendes Sensormusterbeispiel gibt, ändert sich durch das Aufspalten nichts am Wert für die Übereinstimmung.

Tabelle 4:

Als Intervall-Winkel wurde der erste Winkel beibehalten (A1), für die maximal erlaubte Differenz wurde ein proportionaler Wert angegeben (B2). Die Abweichung wurde nicht berücksichtigt (C0). Der proportionale Wert für die maximal erlaubte Differenz wurde variiert.

	Trace 52		Trace 92		Trace 203	
A1, B2, 10, C0	97,67%		80,18%		99,29%	
	zu speziell		zu speziell			
A1, B2, 25, C0	90,8%		75,73%		98,86%	
A1, B2, 40, C0	87,63%		70,6%		98,82%	

Die Bewertung „zu speziell“ wurde hier „von Hand“ ermittelt anhand der Häufigkeit des Auftretens sehr kurzer Intervalle. Eine genauere Definition folgt in Kapitel 4.

Tabelle 5:

Als Intervall-Winkel wurde der erste Winkel beibehalten (A1), für die maximal erlaubte Differenz wurde ein proportionaler Wert angegeben (B2). Zusätzlich fand die Abweichung Berücksichtigung (C1). Der proportionale Wert für die maximal

erlaubte Differenz wurde variiert (3. Parameter) und ebenso die maximal erlaubte Abweichung (5. Parameter).

	Trace 52		Trace 92		Trace 203	
A1, B2, 10, C1, 10	97,67%		80,18%		99,29%	
A1, B2, 10, C1, 25	zu speziell		zu speziell			
A1, B2, 10, C1, 40						
A1, B2, 25, C1, 10	90,8%		75,73%		98,86%	
A1, B2, 25, C1, 25						
A1, B2, 25, C1, 40						
A1, B2, 40, C1, 10	87,63%		70,6%		98,82%	
A1, B2, 40, C1, 25						
A1, B2, 40, C1, 40						

Zum Unterschied zu den Ergebnissen in Tabelle 2 siehe Kapitel 3.3.4 1).

Tabelle 6:

Als Intervall-Winkel wurde der erste Winkel beibehalten (A1), für die maximal erlaubte Differenz wurde ein proportionaler Wert angegeben (B2). Zusätzlich fand die Abweichung Berücksichtigung, und es wurde unterschieden zwischen alternierenden und nicht-alternierenden Folgen (C2). Der proportionale Wert für die maximal erlaubte Differenz wurde variiert (3. Parameter) und ebenso die maximal erlaubte Abweichung für nicht-alternierende Folgen (5. Parameter) sowie für alternierende Folgen (6. Parameter).

	Trace 52		Trace 92		Trace 203	
A1, B2, 10, C2, 10, 25	97,67%		80,18%		99,29%	
A1, B2, 10, C2, 10, 40	zu speziell		zu speziell			
A1, B2, 10, C2, 25, 40						
A1, B2, 10, C2, 40, 55						
A1, B2, 25, C2, 10, 25	90,8%		75,73%		98,86%	
A1, B2, 25, C2, 10, 40						
A1, B2, 25, C2, 25, 40						
A1, B2, 25, C2, 40, 55						
A1, B2, 40, C2, 10, 25	87,63%		70,6%		98,82%	
A1, B2, 40, C2, 10, 40						
A1, B2, 40, C2, 25, 40						
A1, B2, 40, C2, 40, 55						

Tabelle 7:

Der Intervall-Winkel ist der Mittelwert aller Winkel (A2), für die maximal erlaubte Differenz wurde ein konstanter Wert angegeben (B1). Die Abweichung wurde nicht berücksichtigt (C0). Der konstante Wert für die maximal erlaubte Differenz wurde variiert.

	Trace 52		Trace 92		Trace 203	
A2, B1, 10, C0	89,42%	a1, b1	81,86%	b1	97,52%	b1
A2, B1, 25, C0	80,93%	a2	74,68%		92,27%	
A2, B1, 40, C0	78,7%	b2	73,96%	b2	82,69%	b2

Tabelle 8:

Der Intervall-Winkel ist der Mittelwert aller Winkel (A2), für die maximal erlaubte Differenz wurde ein konstanter Wert angegeben (B1). Zusätzlich fand die Abweichung Berücksichtigung (C1). Der konstante Wert für die maximal erlaubte Differenz wurde variiert (3. Parameter) und ebenso die maximal erlaubte Abweichung (5. Parameter).

	Trace 52		Trace 92		Trace 203	
A2, B1, 10, C1, 10	89,42%	a1	81,86%		97,52%	
A2, B1, 10, C1, 25		b1		b1		b1
A2, B1, 10, C1, 40						
A2, B1, 25, C1, 10	80,93%	a2	74,68%	d1	92,43%	d1
A2, B1, 25, C1, 25				d2		d2
A2, B1, 25, C1, 40						
A2, B1, 40, C1, 10	78,7%	c1	74,88%		87,74%	c1
A2, B1, 40, C1, 25	78,7%	b2	73,96%	b2	82,69%	b2
A2, B1, 40, C1, 40		c2		d3		c2

Wie in Tabelle 3 finden sich auch hier nicht-identische Sequenzen von Basiswahrnehmungsmerkmalen mit dem gleichen Wert für die Übereinstimmung mit den Sensormusterbeispielen.

Tabelle 9:

Der Intervall-Winkel ist der Mittelwert aller Winkel (A2), für die maximal erlaubte Differenz wurde ein konstanter Wert angegeben (B1). Zusätzlich fand die Abweichung Berücksichtigung, und es wurde unterschieden zwischen alternierenden und nicht-alternierenden Folgen (C2). Der konstante Wert für die maximal erlaubte Differenz wurde variiert (3. Parameter) und ebenso die maximal erlaubte Abweichung für nicht-alternierende Folgen (5. Parameter) sowie für alternierende Folgen (6. Parameter).

	Trace 52		Trace 92		Trace 203	
A2, B1, 10, C2, 10, 25	89,42%	a1, c1	81,86%	a1	97,52%	a1
A2, B1, 10, C2, 10, 40						
A2, B1, 10, C2, 25, 40						
A2, B1, 10, C2, 40, 55						
A2, B1, 25, C2, 10, 25	82,35%	b1, d1	75,9%	b1	91,84%	
A2, B1, 25, C2, 10, 40						
A2, B1, 25, C2, 25, 40	80,93%	c2, d2	74,68%	c2	92,27%	
A2, B1, 25, C2, 40, 55						
A2, B1, 40, C2, 10, 25	81,85%	e1	75,73%		88,25%	
A2, B1, 40, C2, 10, 40						
A2, B1, 40, C2, 25, 40	78,7%	a2, b2 c3, d3 e2	73,96%	a2, b2 c3	82,69%	a2
A2, B1, 40, C2, 40, 55						

Tabelle 10:

Der Intervall-Winkel ist der Mittelwert aller Winkel (A2), für die maximal erlaubte Differenz wurde ein proportionaler Wert angegeben (B2). Der proportionale Wert für die maximal erlaubte Differenz wurde variiert.

	Trace 52		Trace 92		Trace 203	
A2, B2, 10, C0	96,52%		89,58%		99,09%	a1
	zu speziell		zu speziell			
A2, B2, 25, C0	90,2%		82,2%		98,86%	a2
A2, B2, 40, C0	85,63%		77,84%		98,54%	a3

Tabelle 11:

Der Intervall-Winkel ist der Mittelwert aller Winkel (A2), für die maximal erlaubte Differenz wurde ein proportionaler Wert angegeben (B2). Zusätzlich fand die Abweichung Berücksichtigung (C1). Der proportionale Wert für die maximal erlaubte Differenz wurde variiert (3. Parameter) und ebenso die maximal erlaubte Abweichung (5. Parameter).

	Trace 52		Trace 92		Trace 203	
A2, B2, 10, C1, 10	96,52%		89,58%		99,09%	a1
A2, B2, 10, C1, 25	zu		zu			
A2, B2, 10, C1, 40	speziell		speziell			
A2, B2, 25, C1, 10	90,2%		82,2%		98,86%	a2
A2, B2, 25, C1, 25						
A2, B2, 25, C1, 40						
A2, B2, 40, C1, 10	85,63%		77,84%		98,54%	a3
A2, B2, 40, C1, 25						
A2, B2, 40, C1, 40						

Tabelle 12:

Der Intervall-Winkel ist der Mittelwert aller Winkel (A2), für die maximal erlaubte Differenz wurde ein proportionaler Wert angegeben (B2). Zusätzlich fand die Abweichung Berücksichtigung und es wurde unterschieden zwischen alternierenden und nicht-alternierenden Folgen (C2). Der proportionale Wert für die maximal erlaubte Differenz wurde variiert (3. Parameter) und ebenso die maximal erlaubte Abweichung für nicht-alternierende Folgen (5. Parameter) sowie für alternierende Folgen (6. Parameter).

	Trace 52		Trace 92		Trace 203	
A2, B2, 10, C2, 10, 25	96,52%		89,58%		99,09%	a1
A2, B2, 10, C2, 10, 40	zu		zu			
A2, B2, 10, C2, 25, 40	speziell		speziell			
A2, B2, 10, C2, 40, 55						
A2, B2, 25, C2, 10, 25	90,2%		82,2%		98,86%	a2
A2, B2, 25, C2, 10, 40						
A2, B2, 25, C2, 25, 40						
A2, B2, 25, C2, 40, 55						
A2, B2, 40, C2, 10, 25	85,63%		77,84%		98,54%	a3
A2, B2, 40, C2, 10, 40						
A2, B2, 40, C2, 25, 40						
A2, B2, 40, C2, 40, 55						

3.3.4 Analyse

- 1) Bei der Definition der Halbordnung R_{2_1} lag die Annahme zugrunde, daß ein restriktiverer Parametersatz stets zu einer Sequenz von kürzeren oder gleichlangen Intervallen führt, und eine Sequenz kürzerer Intervalle stets eine bessere Übereinstimmung mit den Sensormusterbeispielen aufweist.

Die Relation „restriktiver“ ist dabei folgendermaßen definiert: ein Parametersatz P1 ist restriktiver als ein Parametersatz P2, wenn P1 bei gleichen Eingabedaten ein Intervall nicht später beendet als P2.

Zunächst seien nur Paare von Parametersätzen betrachtet, bei denen lediglich ein Verfahrensparameter oder ein Parameter variiert. Es wird also lediglich berücksichtigt, welche Paare von Verfahrensparametern bzw. von Parametern Element der Relation „restriktiver“ sind.

- Bei Verfahrensparameter A gilt, daß A1 restriktiver ist als A2, denn die Beibehaltung des ersten Winkels eines Intervalls als dessen Intervall-Winkel führt schneller zu einer Überschreitung der erlaubten Differenz oder Abweichung als die Wahl des Mittelwertes aller Winkel als Intervall-Winkel.
- Bei Verfahrensparameter B gilt im Prinzip, daß das Verhältnis der Werte B1 und B2 bezüglich der Relation abhängt von der absoluten Größe des Intervall-Winkels. Es kommen jedoch keine Winkel vor, deren Absolutwert größer ist als 90 (vgl. mit Kapitel 3.2.1.1). Somit gilt für alle vorkommenden Winkel und beliebiges X: $X\%$ des Absolutwertes eines solchen Winkels $< X$. B2 ist also restriktiver als B1.
- Bei Verfahrensparameter C gilt, daß C1 restriktiver ist als C2, da bei einer Abweichung über der maximal erlaubten das Intervall bei C1 in jedem Fall beendet wird, bei C2 dagegen nur in bestimmten Fällen. Außerdem gilt, daß C2 restriktiver ist als C0 aufgrund der Abweichung als zusätzliches Kriterium, das zum Beenden des Intervalls führen kann.
- Bei den Parametern für die maximal erlaubte Differenz und die maximal erlaubte Abweichung ist klar, daß ein Parameter umso restriktiver ist, je kleiner dieser Wert ist.

Gemäß obiger Annahme müßten also beispielsweise die vom Parametersatz A1,B2,10,C0 erzeugten Sequenzen von Basiswahrnehmungsmerkmalen einen mindestens so großen Wert für die Übereinstimmung mit den Sensormusterbeispielen aufweisen wie die von A2,B2,10,C0 erzeugten Sequenzen. Tatsächlich ist bei Trace 92 jedoch gerade die umgekehrte Beziehung gegeben wie auch zum Teil bei Trace 203 (siehe Tabellen 4 und 10). Für die angenommene Veränderung der Übereinstimmungsraten bei Variation des Verfahrensparameters A lassen sich noch weitere Gegenbeispiele finden; gleiches gilt auch für die Variation von Verfahrensparameter B und C und für die Variation der Parameter. Siehe etwa für Verfahrensparameter B die Ergebnisse für Trace 92 in den Tabellen 9 und 12, für Verfahrensparameter C die Ergebnisse für Trace 52 in den Tabellen 8 und 9 (höhere Übereinstimmung bei C2 als bei C1) und für Trace 203 in den Tabellen 7 und 9 (höhere Übereinstimmung bei C0 als bei C2).

Woran liegt es aber nun, daß die Annahme falsch ist? Bereits der erste Teil der Annahme ist nicht korrekt. Ein Parametersatz P1, der restriktiver als ein Parametersatz P2 ist, erzeugt per definitionem bei gleichen Eingabedaten ein kürzeres Intervall als P2 oder ein gleichlanges Intervall. Wenn aber P1 ein kürzeres Intervall bildet als P2, muß i. a. beim jeweils darauffolgenden Intervall eine andere Folge von Meßdaten verarbeitet werden. Die Voraussetzung der gleichen Eingaben gilt also nicht mehr! Das Problem in diesem Fall ist, daß die ersten beiden Datensätze eines Intervalls den Intervall-Winkel bestimmen, an dem alle weiteren Winkel gemessen werden, und bei unterschiedlichen Anfangszeitpunkten in der Regel unterschiedliche Intervall-Winkel gebildet werden.

Zum zweiten Teil der Annahme - eine Sequenz kürzerer Intervalle weist stets eine bessere Übereinstimmung mit den Sensormusterbeispielen auf - ist anzumerken, daß lediglich die Wahrscheinlichkeit für eine gute Übereinstimmung von Basiswahrnehmungsmerkmalen und Sensormusterbeispielen umso größer ist, je kleiner die erzeugten Intervalle bei den Merkmalen sind - die Wahrscheinlichkeit ist aber eben nicht 1. Auf Beispiele hierzu ist bei den Tabellen 3 und 8 bereits hingewiesen worden.

Wenn auch keine mehr als einelementige Menge M_1 von Parametersätzen existiert, auf der eine Halbordnung R_1 gemäß der oben definierten Relation „restriktiver“ definiert ist, so daß die geforderte Eigenschaft für f gilt, so scheint die angenommene Beziehung doch zumindest in den überwiegenden Fällen zuzutreffen. Siehe etwa die Tabellen 2 und 5 in Kapitel 3.3.3: Der Effekt, daß erst bei größeren erlaubten Differenzen die Abweichung an Bedeutung gewinnt, zeigt sich auch hier. Nur ist nicht der für die erlaubte Differenz angegebene Parameter verantwortlich für die besseren Ergebnisse in Tabelle 5, sondern die Generierung mit dem restriktiveren Wert B2 anstelle von B1.

Bezüglich der Frage, ob es möglich ist, Sequenzen von Basiswahrnehmungsmerkmalen zu generieren, die gemäß der hier vorgegebenen Bewertung sehr gut geeignet sind für das Lernen der Sensormuster, fallen bei den Testergebnissen die bei allen getesteten Parametersätzen sehr guten Ergebnisse beim Übereinstimmungsgrad mit den Sensormusterbeispielen für Trace 203 auf. Sie resultieren aus der Tatsache, daß der Trace fast ausschließlich aus Drehungen und Fahrten parallel entlang einer angemessenen Kante besteht.

Bei den parallelen Fahrten treten sehr gleichmäßige Veränderungen der gemessenen Distanzen auf, so daß auch bei nur geringer erlaubter maximaler Differenz alle Winkel in einem Intervall zusammengefaßt werden, das genau mit dem Intervall eines *s_line*-Beispiels übereinstimmt.

Außerdem wirken sich auch Drehungen positiv auf die Übereinstimmung der Basiswahrnehmungsmerkmale mit den Sensormusterbeispielen aus. Bei Drehungen werden Basiswahrnehmungsmerkmale mit einem Merkmalssymbol für Sonderfälle (siehe Kap. 3.2.1.2) generiert. Das hat folgenden Effekt: Nehmen wir an, daß die Basiswahrnehmungsmerkmale mit einem Parametersatz generiert werden, der für den aktuellen Trace nicht geeignet ist. Dann werden bei der Entscheidung, ein Intervall zu beenden, häufig Fehler gemacht. Wenn der Parametersatz beispielsweise eine zu geringe

Differenz erlaubt, wird ein Intervall möglicherweise zu früh beendet. Diese Fehler können sich zufällig gegenseitig aufheben. Wahrscheinlicher ist jedoch, daß die Fehler sich aufsummieren und die Zeitintervalle der Basiswahrnehmungsmerkmale überhaupt nicht mehr mit denen der Sensormusterbeispiele übereinstimmen. Das ist aber nur möglich bei einer Folge von Normalfällen. Nur dann wird nämlich mehrmals hintereinander aufgrund der gewählten Parameter entschieden, ob ein Intervall beendet wird. Bei Sonderfällen dagegen hängt die Entscheidung, ob ein Intervall beendet wird, nicht vom gewählten Parametersatz ab. Ein Basiswahrnehmungsmerkmal für einen Sonderfall (außer *single_peak*) ist stets korrekt³⁶. Das Auftreten eines solchen Sonderfalles wirkt als Trennsignal und sorgt dafür, daß die Anfangszeitpunkte des Basiswahrnehmungsmerkmals und des Sensormusterbeispiels, die auf einen solchen Sonderfall folgen, übereinstimmen.

Somit kann man folgern, daß mit großer Wahrscheinlichkeit für diejenigen Traces eine größere Übereinstimmung von Basiswahrnehmungsmerkmalen und Sensormusterbeispielen erreicht werden kann, die einen hohen Anteil an diesen Sonderfällen aufweisen, die gleichmäßig im Trace verteilt auftreten. Am Ende des Kapitels 3.2.1.2 wurde bereits erwähnt, daß der Anteil der Sonderfälle im Durchschnitt bei 50% liegt, es aber auch Fälle mit einem höheren Anteil gibt. Erwartungsgemäß trifft auf Trace 203 der dort genannte Anteil an Sonderfällen von 64% zu. An diesem Anteil läßt sich nicht ablesen, ob die Sonderfälle gleichmäßig im Trace verteilt sind. Für Trace 203 trifft das jedoch für die Drehungen zu (siehe Kapitel 3.3.2.3, Abbildung 13). Entsprechend erreicht ein Trace - t120 - mit einem Anteil von 71% Normalfällen nur eine Übereinstimmung mit den Sensormusterbeispielen von 77,38%.

Ein grundsätzliches Problem hinsichtlich der Übereinstimmung von Basiswahrnehmungsmerkmalen und Sensormusterbeispielen tritt auf, wenn der Roboter durch eine Tür fährt oder an einer Tür oder einer Zimmerecke vorbeifährt - leider handelt es sich dabei gerade um die interessanten Abschnitte eines Trace. In diesen Fällen wechselt die Kante, die angemessen wird. Gemäß der Definition für Sensormuster werden zwei Beispiele für *s_line* und ein Beispiel für *s_convex* bzw. *s_concave* generiert, z. B.:

s_line(t92,s0,3,4,diagonal).

s_line(t92,s0,5,10,diagonal).

s_convex(t92,s0,3,10,straight_towards).

36 „Korrekt“ bezieht sich natürlich nur auf die Verarbeitung der zur Verfügung stehenden Meßdaten. Die Unzuverlässigkeit der Ultraschallsensoren wird dabei außer acht gelassen. Berücksichtigt man sie, dürfte in keinem Fall von korrekten Basiswahrnehmungsmerkmalen gesprochen werden.

Der Sonderfall *single_peak* ist hier ausgenommen, da er von den benachbarten Basiswahrnehmungsmerkmalen abhängt und damit nicht wie die übrigen Sonderfälle unabhängig vom gewählten Parametersatz generiert wird.

Zum Zeitpunkt 4 wird noch die Kante 2 angemessen, während zum Zeitpunkt 5 bereits die Kante 3 erfaßt wird.

Da die Information über die angemessene Kante bei der Generierung der Basiswahrnehmungsmerkmale nicht zur Verfügung steht, wird mit großer Wahrscheinlichkeit kein Basiswahrnehmungsmerkmal generiert, das zu den beiden *s_line*-Beispielen paßt. Voraussetzung für ein passendes Basiswahrnehmungsmerkmal ist ja, daß dessen Intervall ein Teil des Intervalls des Beispiels ist, was sicher erreicht wird, wenn durch die Wahl eines sehr restriktiven Parametersatzes nur Intervalle der Länge 1 erzeugt werden. Bei der angestrebten Zusammenfassung ähnlicher Winkel in einem Zeitintervall ist es dagegen recht unwahrscheinlich, daß die Zeitpunkte des Kantenwechsels (im Beispiel: 4 und 5) nicht mitten in einem Zeitintervall eines Basiswahrnehmungsmerkmals liegen. Die berechneten Winkel zu obigem Beispiel sind:

zwischen Zeitpunkt . . .

3 und 4: -47

4 und 5: -44

5 und 6: -40

6 und 7: -32

Es ist also keine ausreichend große Veränderung der gemessenen Distanzen mit einem Kantenwechsel korreliert.

Die aufmerksame Leserin wird sich vielleicht erinnern, daß in Kapitel 3.2.1.1 zwei Merkmalsymbole vorgestellt wurden, deren Auftreten einen Kantenwechsel anzeigen sollte, nämlich *incr_peak* und *decr_peak*. Diese Eigenschaft gilt nach wie vor. Was aber nicht gilt, ist die umgekehrte Folgerung: bei einem Kantenwechsel wird eben - auch bei Wahl eines geeigneten Parametersatzes - nicht immer ein *incr_peak*- bzw. *decr_peak*-Intervall generiert. Die Fälle, in denen ein solches Intervall erzeugt wird, sind gekennzeichnet durch den Wechsel zwischen zwei versetzt parallel liegenden Kanten.

Beispiel:


stable(t203,s6,182,186,0).

decr_peak(t203,s6,186,187,-87).

stable(t203,s6,187,189,0).

Dem entspricht das Sensormusterbeispiel *s_jump*(t203,s6,182,189,*diagonal*).

Die vom Sensor 6 erfaßten Kanten sind markiert.



Ein weiteres Beispiel zum Kantenwechsel:

s_line(t203,s2,196,208,diagonal).

s_convex(t203,s2,195,208,straight_towards).

Voraus geht ein Zeitintervall, in dem der Sensor 2 nur erfolglose Messungen durchgeführt hat. Zum Zeitpunkt 195 wird die Kante 3 angemessen, zum darauffolgenden Zeitpunkt bereits die Kante 2. Da nur für Intervalle mit einer Länge von mindestens 1 überhaupt Beispiele generiert werden, wird das Erfassen der Kante 2 nicht durch ein Beispiel für *s_line* wiedergegeben, taucht aber im Beispiel für *s_convex* auf.

Bei der Generierung der Basiswahrnehmungsmerkmale werden die Winkel bis zum Zeitpunkt 195 in einem *no_measurement*-Intervall zusammengefaßt. Das folgende Merkmal beginnt, passend für das Beispiel für *s_convex*, bei Zeitpunkt 195. Aus den gleichen Gründen wie im vorherigen Beispiel angegeben ist es aber auch in diesem Fall sehr unwahrscheinlich, eine passende Sequenz von Basiswahrnehmungsmerkmalen für das *s_line*-Beispiel zu generieren. Die Wahrscheinlichkeit für die Generierung eines passenden Basiswahrnehmungsmerkmals für *s_convex* bzw. *s_concave* ist demgegenüber hoch.

Diese Gegebenheiten sprechen nun keineswegs gegen das Verfahren zur Generierung der Basiswahrnehmungsmerkmale, sondern eher gegen die Verwendung von *s_line*, wenn daraus das Sensormuster für konvexe bzw. konkave Ecken - *s_convex* bzw. *s_concave* - gebildet wird.

- 2) Die Beziehung zwischen Parametersatz und generierter Sequenz von Basiswahrnehmungsmerkmalen, die hier betrachtet wurde, ist ein Spezialfall der bei 1) untersuchten Beziehung, da nicht nur gefordert wird, daß ein Parametersatz kürzere oder gleichlange Intervalle erzeugt als ein anderer, sondern zusätzlich, daß ein längeres Intervall in kürzere Intervalle aufgespalten wird, die aneinandergereiht das längere Intervall ergeben. Da schon die allgemeinere Forderung nicht erfüllt wird, ist klar, daß auch für diesen Spezialfall keine nicht-triviale Menge von Parametersätzen existiert, auf der die Halbordnung „spezieller als oder gleich“ definiert ist und die geforderte Eigenschaft für *f* gilt.
- 3) Es ist keine absolute Bewertung eines Parametersatzes möglich bezüglich des Feinheitsgrades der erzeugten Sequenz.

Ein Beispiel zur Datenabhängigkeit dieser Eigenschaft: Mit dem Parametersatz A1,B2,10,C0 werden bei Trace 52 und Trace 92 Sequenzen von Basiswahrnehmungsmerkmalen erzeugt, die Teilsequenzen der Art enthalten, daß zehn oder noch mehr Intervalle der Länge 1 aufeinander folgen, etwa

something_happened(t92,332,s2,48,49,-25).

something_happened(t92,332,s2,49,50,-32).

something_happened(t92,332,s2,50,51,-24).

usw.

Derartige Teilsequenzen treten bei Trace 203 wesentlich seltener auf und sind mit einer Gesamtlänge von maximal 4 deutlich kürzer. Ursache hierfür ist, daß bei den zugrundeliegenden Meßdaten für Trace 92 mehrfach Veränderungen der Winkel auftreten, die gerade so groß sind, daß die Winkel gemäß dem Parametersatz nicht zu einem Intervall zusammengefaßt werden, während sich bei Trace 203 die gemessenen Distanzen über größere Zeiträume sehr gleichmäßig verändern, was zu annähernd identischen Winkeln im jeweiligen Zeitraum führt. Das gleiche Phänomen wurde bereits bei der Frage betrachtet, ob es möglich ist, Sequenzen von Basiswahrnehmungsmerkmalen zu generieren, die gemäß der hier vorgegebenen Bewertung sehr gut geeignet sind für das Lernen der Sensormuster.

3.3.5 Folgerungen für das Lernverfahren

Aufgrund des im vorangehenden Kapitel dargestellten grundsätzlichen Problems bei der gesuchten geordneten Menge $(M_1; R_1)$ werden auch andere Kriterien für die Beendigung eines Intervalls, die hier nicht berücksichtigt wurden, keine positiven Ergebnisse zur Existenz der gesuchten Halbordnung R_1 liefern. Möglich wäre noch, daß es neben der Länge der Intervalle andere Kriterien für Sequenzen von Basiswahrnehmungsmerkmalen gibt, die zum Lernen gut geeignet sind, und es eine Halbordnung auf M_2 bezüglich dieser Kriterien gibt, so daß $(M_1; R_1)$ definiert werden kann und f die geforderte Eigenschaft hat. Dieser Ansatz wird aber zunächst nicht weiter verfolgt.

Wenn die gesuchte Halbordnung R_1 mit der geforderten Eigenschaft von f auch nicht existiert, so dokumentieren die Testergebnisse doch, daß bei

- Einschränkung von M_1 auf eine Menge von Parametersätzen, bei denen lediglich ein Verfahrensparameter oder ein Parameter variiert,
 - der in Kapitel 3.3.4 definierten Relation „restriktiver“ als Halbordnung R_1
- und
- der in Kapitel 3.3.2.1 definierten Halbordnung R_{2_1} „spezieller“ auf den generierten Sequenzen von Basiswahrnehmungsmerkmalen

f diese Eigenschaft zumindest in den meisten Fällen hat. Es ist also durchaus erfolgversprechend, ein Lernverfahren anzuwenden, das in einem gemäß dieser Halbordnung R_1 geordneten Hypothesenraum nach einem geeigneten Parametersatz sucht.

Lernen von Parametersätzen wird hier als Suche in einem *version space* [Mitchell 1982] aufgefaßt. Es gibt jedoch einige Unterschiede zu Mitchell's Versionenraummethode. Es wird hier keine bidirektionale Suche durchgeführt. Es wird auch nicht aus positiven und negativen Beispielen gelernt, wie Mitchell sie voraussetzt. Gäbe es diese „idealen“ Eingaben, könnte man bestehende Verfahren zum Lernen einsetzen. Insbesondere kann für das Ergebnis einer Suche in einem geordneten Raum von Parametersätzen nicht garantiert werden, daß es sich um den am besten geeigneten Parametersatz unter den vorhandenen handelt. Gäbe es die gesuchte Halbordnung R_1 , so daß die geforderte

Eigenschaft von f gilt, dann könnte man diese Garantie geben. Die idealisierten Bedingungen bei Mitchell's Verfahren garantieren dagegen, daß das korrekte Ergebnis gefunden wird. Immerhin ist aber die Wahrscheinlichkeit, den besten Parametersatz zu finden, sehr hoch.

Es stellt sich als nächstes die Frage, welche Parametersätze M_1 enthalten sollte. Da die Berücksichtigung der Abweichung keine Verbesserung bei der Übereinstimmung der generierten Sequenzen von Basiswahrnehmungsmerkmalen mit den Sensormusterbeispielen mit sich bringt, ist die Auswahl zu treffen aus den Parametersätzen mit dem Wert C_0 für Verfahrensparameter C , das wären also die Kombinationen A_1, B_1, C_0 , A_1, B_2, C_0 , A_2, B_1, C_0 und A_2, B_2, C_0 . Auch hier zeigen die Testergebnisse keine wesentlichen Unterschiede, so daß für das Lernverfahren die Kombination gewählt wurde, die für die wahrscheinlich sinnvollsten Basiswahrnehmungsmerkmale sorgt: A_2 , da der Mittelwert der im Zeitintervall zusammengefaßten Winkel sie besser repräsentiert als der erste dieser Winkel, und B_1 , da eine maximal erlaubte Differenz konstanter Größe sinnvoller erscheint als eine maximal erlaubte Differenz, die umso größer ist, je größer der Absolutwert des Intervall-Winkels ist.

4 Lernen eines geeigneten Parametersatzes für die Generierung der Basiswahrnehmungsmerkmale

4.1 Das Lernverfahren

Wie bereits in Kapitel 3.3.5 dargestellt soll das Lernverfahren einen Hypothesenraum durchsuchen, der Parametersätze mit der Kombination A_2, B_1, C_0 enthält und geordnet ist gemäß der Halbordnung R_1 , wie sie in Kapitel 3.3.4 definiert ist. Gesucht wird nach einem Parametersatz, der

- 1) eine möglichst große Übereinstimmung mit den Sensormusterbeispielen aufweist
- und
- 2) nicht zu speziell ist.

- 1) Die Übereinstimmung mit den Sensormusterbeispielen wird berechnet wie in Kapitel 3.3.2.1 beschrieben. Vorgegeben wird eine Mindestübereinstimmung: wenn sie erreicht ist, wird nicht weiter nach einem Parametersatz gesucht, mit dem vielleicht Basiswahrnehmungsmerkmale mit noch besserer Übereinstimmung generiert werden.
- 2) Bei den Testergebnissen in Kapitel 3.3.3 wurden einige Sequenzen von Basiswahrnehmungsmerkmalen von Hand (oder besser: durch flüchtiges Betrachten) als „zu speziell“ eingestuft aufgrund des Feinheitsgrades der generierten Sequenzen, wobei häufiges Auftreten von Intervallen der Länge 1 sofort erkennbar war und den Ausschlag für die Bewertung gab. Werden solche Basiswahrnehmungsmerkmale zum Lernen der Sensormuster verwendet, können Regeln entstehen, die so speziell sind, daß sie nur in sehr wenigen Situationen angewendet werden können. In diesem Fall könnte man von „*over-fitting*“ sprechen. Um zu verhindern, daß solche Regeln gelernt werden, muß bei der Auswahl eines geeigneten Parametersatzes darauf geachtet werden, daß der Anteil dieser kurzen Intervalle nicht zu groß ist.

Das Festsetzen einer Bewertung des Feinheitsgrades der generierten Sequenzen muß für das Lernverfahren automatisiert werden. Dazu wurde das Verfahren zur Bewertung der Basiswahrnehmungsmerkmale ergänzt um eine Komponente, die den Anteil von Intervallen der Länge 1 und den Anteil von Intervallen der Länge 2 an der Gesamtlänge der geeigneten Basiswahrnehmungsmerkmale berechnet.

Das Auftreten dieser kurzen Intervalle in Zeiträumen, für die es keine Sensormusterbeispiele gibt, wird also nicht berücksichtigt. Das ist auch nicht notwendig, denn Basiswahrnehmungsmerkmale, für die es keine

Sensormusterbeispiele gibt, werden nicht zum Lernen der Sensormuster herangezogen. Die Gefahr, daß Regeln gelernt werden, die zu speziell sind, besteht bei diesen Basiswahrnehmungsmerkmalen also nicht.


Auch bei der Berechnung des Anteils dieser kurzen Intervalle an der Gesamtlänge der geeigneten Basiswahrnehmungsmerkmale müssen Intervalle mehrfach berücksichtigt werden gemäß der Anzahl passender Sensormusterbeispiele (vgl. mit Kapitel 3.3.2.1).

Diese Anteile wurden berechnet für die als „zu speziell“ eingestuft und für einige der anderen bei den Tests generierten Basiswahrnehmungsmerkmale. Für die erstgenannten ergaben sich Anteile in der Größenordnung von 21% bis 26% für die Intervalle der Länge 1, und für die letztgenannten lagen die Anteile dieser Intervalle zwischen 1% und 5%. In beiden Fällen ist der Anteil der Intervalle der Länge 2 stets etwa halb so groß, so daß er für die Bewertung nicht relevant ist. Es sei noch erwähnt, daß diese kurzen Intervalle gleichmäßig verteilt sind auf Zeiträume, für die es Sensormusterbeispiele gibt, wie auf Zeiträume, für die es keine Sensormusterbeispiele gibt. Wenn also beim Betrachten der Basiswahrnehmungsmerkmale der Eindruck eines hohen Anteils an kurzen Intervallen entsteht, dann bestätigt sich dieser Eindruck bei der Berechnung des Anteils.

Eingedenk der Tatsache, daß bei der Generierung der Basiswahrnehmungsmerkmale kompliziertere Verfahren wie die Berücksichtigung von Abweichung und alternierenden Folgen keine Verbesserung bewirken, sollte hier zunächst ein simples Kriterium für die Bewertung gewählt werden. Das einfachste Kriterium ist ein fester Prozentsatz für den Anteil der Intervalle mit Länge 1, bei dessen Überschreitung die Sequenz von Basiswahrnehmungsmerkmalen dann als „zu speziell“ eingestuft wird. Die Betrachtung der Basiswahrnehmungsmerkmale, für die die obigen Anteile berechnet wurden, führt zu der Annahme, daß dieser Prozentsatz durchaus noch etwas größer sein kann als 5, aber deutlich unter 20 liegen sollte. Um den Wert genau festzulegen, wurden - natürlich gemäß der Halbordnung R_1 - weitere Parametersätze getestet. Der Vergleich zwischen berechnetem Anteil von Intervallen der Länge 1 und intuitiver Bewertung führte zur Festsetzung eines Wertes von 9%.

Festzulegen ist außerdem noch, welche Werte für Parameter B, also die maximal erlaubte Differenz, gewählt werden, und wie der geordnete Hypothesenraum strukturiert wird, um eine effiziente Suche zu ermöglichen.

Da die Werte für die Verfahrensparameter nicht verändert werden, enthält der Hypothesenraum nur die Werte für Parameter B. Der Parametersatz wird dann jeweils aus den feststehenden Werten für die Verfahrensparameter und einem Wert für Parameter B zusammengesetzt. Als Struktur wurde ein Binärbaum gewählt mit dem Wert 16 als Wurzel. Bis auf die Wurzel gilt für alle Knoten des Baumes, daß die Höhen der beiden Teilbäume identisch sind.



Daß es sich bei dem Baum, der den Hypothesenraum definiert, nicht um einen AVL-Baum handelt, in dem man ja sehr effizient suchen kann, ist in diesem speziellen Fall für ein schnelles Finden der Lösung nicht von Bedeutung. Wichtig ist hingegen, daß der Teilbaum der Wurzel, in dem sich höchstwahrscheinlich der gesuchte Wert befindet, eine möglichst geringe Höhe besitzt. Für die Suchdauer hat die größere Höhe des rechten Teilbaumes der Wurzel nur in sehr wenigen Fällen eine negative Auswirkung. Das wäre auch bei einer Erweiterung dieses Teilbaumes um größere Werte noch der Fall. Trotzdem wurde auf diese Erweiterung verzichtet, da auch von der größten hier berücksichtigten erlaubten Differenz angenommen werden kann, daß sie zum Zusammenfassen sehr unterschiedlicher Winkel führt. Die generierten Sequenzen von Basiswahrnehmungsmerkmalen erreichen dadurch nur eine geringe Übereinstimmung mit den Sensormusterbeispielen. Bei noch größeren maximal erlaubten Differenzen wäre dieses Ergebnis noch wahrscheinlicher.

Zur Vollständigkeit des gewählten Hypothesenraumes ist zu sagen, daß sie ebensowenig garantiert werden kann wie die Eigenschaft des Generierungsverfahrens, eine geordnete Menge von Parametersätzen abzubilden auf eine geordnete Menge von Sequenzen von Basiswahrnehmungsmerkmalen. Insbesondere stellt sich die Frage, ob nicht auch noch kleinere Schritte bei der maximal erlaubten Differenz nötig sind. Das würde dann erfordern, daß die Blätter des oben dargestellten Baumes zu inneren Knoten werden und jeweils noch ein linkes und ein rechtes Blatt ergänzt wird, das den Wert des Elternknotens $-0,5$ bzw. $+0,5$ erhält. Das Anhängen neuer Blätter läßt sich natürlich beliebig fortsetzen, was zu immer kleineren Schritten bei den maximal erlaubten Differenzen und zu einem größeren Hypothesenraum führt. Die Notwendigkeit dieser Ergänzung sollten die Tests (siehe Kapitel 4.2) klären.

Wie funktioniert nun die Suche im Hypothesenraum? Das Lernverfahren berechnet die Übereinstimmung der generierten Basiswahrnehmungsmerkmale mit den Sensor-musterbeispielen und den Anteil der Intervalle der Länge 1 und entscheidet aufgrund dieser Werte, der vorgegebenen minimalen

Übereinstimmung und der Position des aktuellen Parametersatzes im Hypothesenraum (an einem inneren Knoten oder an einem Blatt), ob noch ein weiterer Parametersatz ausprobiert werden muß, und wenn ja, welcher. Der nächste zu testende Parametersatz erhält als maximal erlaubte Differenz jeweils den Wert an der Wurzel eines Teilbaumes des aktuellen Knotens. Bricht das Verfahren ab, wird unter den beiden zuletzt getesteten Parametersätzen der geeignetere ausgewählt.

Bei der Suche im Hypothesenraum möglicher Parametersätze wählt das Verfahren einen Pfad von der Wurzel zu einem Blatt des Hypothesenraumes. Die Suche kann unter zwei Bedingungen vor Erreichen eines Blattes abgebrochen werden:

- Wenn sich die Übereinstimmung mit den Sensormusterbeispielen gegenüber dem vorherigen Parametersatz nicht verändert hat, ist wahrscheinlich der Punkt erreicht, an dem ein weiteres Verringern der maximal erlaubten Differenz keine Verbesserung der Übereinstimmung mehr bringt, sondern nur noch eine Erhöhung des Anteils der Intervalle der Länge 1 (siehe dazu Kapitel 4.2.3, Trace 54 und 94).
- Die generierten Basiswahrnehmungsmerkmale sind nicht zu speziell, und die minimal geforderte Übereinstimmung ist erreicht.

Bei sehr hohen Werten für die geforderte Übereinstimmung wird die Suche mit Sicherheit nicht wegen der Erfüllung dieses Kriteriums vor Erreichen eines Blattes abgebrochen.

Lernen eines geeigneten Parametersatzes

(+ Meßdaten, - best_param)

initialisieren des Parametersatzes(- param),

initialisieren der „alten Werte“(- alter_param, - alte_Übereinstimmung, - alter_Anteil),

generieren von Basiswahrnehmungsmerkmalen(+ param, + Meßdaten, - akt_BWM),

suchen im Hypothesenraum möglicher Parametersätze(+ akt_BWM, + alter_param,

+ param, + alte_Übereinstimmung, + alter_Anteil, - best_param).

Das Argument param ist ein Baum, und zwar der noch zu durchsuchende Hypothesenraum. Bei jedem erneuten Aufruf der Prozedur **suchen im Hypothesenraum möglicher Parametersätze** wird der Hypothesenraum eingeschränkt (siehe Algorithmus auf der folgenden Seite).

Die Basiswahrnehmungsmerkmale werden jeweils mit dem Parametersatz an der Wurzel des noch zu durchsuchenden Hypothesenraumes generiert. Da in der Regel das Lernverfahren nicht bereits nach dem ersten getesteten Parametersatz abbricht, muß das Verfahren zur Generierung der Basiswahrnehmungsmerkmale mehrmals aufgerufen werden. Dabei müssen jeweils die gleichen Meßdaten nochmals eingegeben werden, da andernfalls das Lernergebnis verfälscht wird (Grund dafür ist die mangelnde Übertragbarkeit des Lernergebnisses, siehe

Kapitel 4.2.3). Zu diesem Zweck muß entweder die Datenhaltung die Meßdaten eines Trace speichern, oder der Roboter muß den Trace wiederholen. Im letzteren Fall werden die neuen Meßdaten nur annähernd mit den alten Meßdaten übereinstimmen, was aber für das Lernverfahren ausreichen müßte.

Das evtl. nötige Speichern der Meßdaten in der Lernphase ist kein Widerspruch zur Forderung, daß die Meßdaten inkrementell verarbeitet werden müssen. Eine inkrementelle Verarbeitung der Meßdaten nötig ist, da sie in der Anwendungsphase die Voraussetzung für ein direktes Reagieren auf Wahrnehmungen ist.

suchen im Hypothesenraum möglicher Parametersätze

(+ akt_BWM, + alter_param, + param, + alte_Übereinstimmung, + alter_Anteil, - best_param)

 bewerten der Basiswahrnehmungsmerkmale

 (+ akt_BWM, - akt_Übereinstimmung, - akt_Anteil)

 WENN akt_Übereinstimmung = alte_Übereinstimmung

 DANN auswählen Parametersatz

 (+ param, + akt_Übereinstimmung, + akt_Anteil, + alter_param, + alte_Übereinstimmung, + alter_Anteil, - best_param)

 SONST

 WENN akt_Anteil \leq 9%

 DANN WENN akt_Übereinstimmung \geq min_Übereinstimmung

 DANN auswählen Parametersatz

 (+ param, + akt_Übereinstimmung, + akt_Anteil, + alter_param, + alte_Übereinstimmung, + alter_Anteil, - best_param)

 SONST neuer_param := linker Teilbaum(param)

 WENN neuer_param = {}

 DANN auswählen Parametersatz

 (+ param, + akt_Übereinstimmung, + akt_Anteil, + alter_param, + alte_Übereinstimmung, + alter_Anteil, - best_param)

 SONST generieren von

 Basiswahrnehmungsmerkmalen

 (+ neuer_param, + Meßdaten, - neue_BWM),

 suchen im Hypothesenraum möglicher Parametersätze

 (+ neue_BWM, + param, + neuer_param, + akt_Übereinstimmung, + akt_Anteil, - best_param)

 SONST neuer_param := rechter Teilbaum(param)

 WENN neuer_param = {}

DANN auswählen Parametersatz
(+ param, + akt_Übereinstimmung, + akt_Anteil,
+ alter_param, + alte_Übereinstimmung, +
alter_Anteil,
- best_param)

SONST generieren von Basiswahrnehmungsmerkmalen
(+ neuer_param, + Meßdaten, - neue_BWM),
suchen im Hypothesenraum möglicher
Parametersätze
(+ neue_BWM, + param, + neuer_param,
+ akt_Übereinstimmung, + akt_Anteil, - best_param
)

Bei der Entscheidung zwischen den beiden zuletzt betrachteten Parametersätzen in **auswählen Parametersatz** geht es darum, den besser geeigneten Parametersatz anhand der Werte für Übereinstimmung und Anteil der Intervalle der Länge 1 zu ermitteln. Da die Übereinstimmung möglichst groß und der Anteil dieser Intervalle möglichst klein sein sollte, wird der Parametersatz als besser geeignet angesehen, bei dem die Differenz

Übereinstimmung - Anteil der Intervalle der Länge 1

größer ist als beim anderen Parametersatz. Sind die Differenzen bei beiden Parametersätzen identisch, wird dem Anteil dieser Intervalle eine größere Bedeutung beigemessen, da angenommen werden kann, daß die hier dargestellte Entscheidung ohnehin nur getroffen werden muß, wenn schon eine sehr gute Übereinstimmung erreicht ist relativ zu dem, was für die jeweiligen Meßdaten überhaupt erreichbar ist. In diesem Fall wird also der Parametersatz ausgewählt, der die Basiswahrnehmungsmerkmale mit dem geringeren Anteil an Intervallen der Länge 1 generiert hat. Stimmt auch dieser Wert bei beiden Parametersätzen überein, sind die generierten Sequenzen von Basiswahrnehmungsmerkmalen höchstwahrscheinlich identisch, und es ist egal, welcher Parametersatz ausgewählt wird. Die willkürliche Wahl fiel auf den aktuellen Parametersatz.

Im Fall, daß bereits mit dem zuerst getesteten Parametersatz Basiswahrnehmungsmerkmale generiert werden, die die geforderte minimale Übereinstimmung erreichen und nicht zu speziell sind, kann kein Vergleich durchgeführt werden, und es wird der aktuelle Parametersatz ausgegeben.

auswählen Parametersatz

```
( + param, + akt_Übereinstimmung, + akt_Anteil,  
+ alter_param, + alte_Übereinstimmung, + alter_Anteil, - best_param )  
  alte_Diff := alte_Übereinstimmung - alter_Anteil,  
  akt_Diff := akt_Übereinstimmung - akt_Anteil  
  WENN  alte_Diff > akt_Diff  
  DANN  best_param := alter_param  
  SONST WENN  akt_Diff > alte_Diff  
        DANN  best_param := akt_param  
        SONST WENN  alter_Anteil < akt_Anteil  
              DANN  best_param := alter_param  
              SONST best_param := akt_param
```

4.2 Test und Analyse des Lernverfahrens

4.2.1 Ziel der Tests

Mit den Tests sollte folgenden Fragen nachgegangen werden:

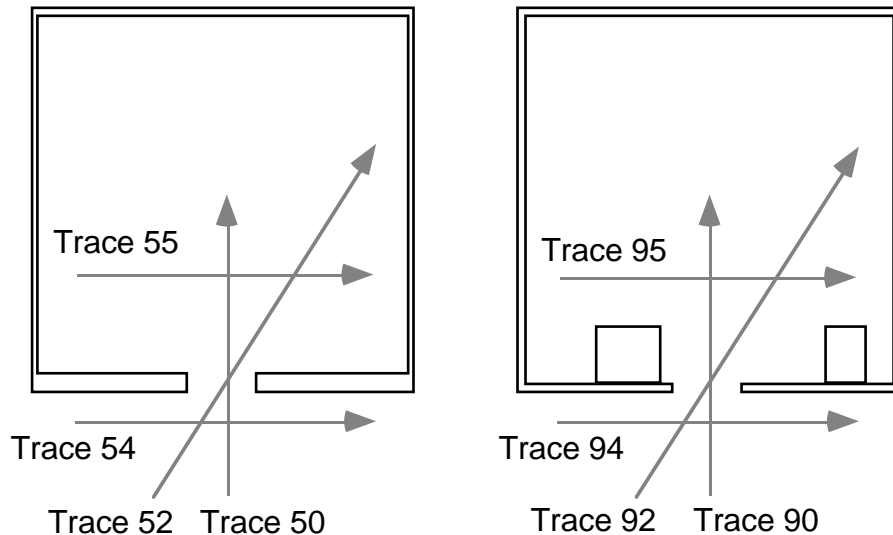
- 1) Ist die Wahl einer maximal erlaubten Differenz von 16 als Startwert der Suche im Hypothesenraum sinnvoll?
- 2) Da es keine Garantie gibt, den besten, im Hypothesenraum vorhandenen Parametersatz zu finden: Wie gut sind die Lernergebnisse?

Zur Beantwortung dieser Frage wurden für zusätzliche Parametersätze die Übereinstimmung mit den Sensormusterbeispielen und der Anteil der Intervalle der Länge 1 berechnet. Bezogen auf den vom Lernverfahren ausgewählten Parametersatz wurden die Parametersätze mit den drei nächstkleineren und den drei nächstgrößeren im Hypothesenraum vorhandenen Werten für die maximal erlaubte Differenz überprüft. Für Werte, die noch stärker abweichen von der maximal erlaubten Differenz des vom Lernverfahren ausgewählten Parametersatzes, ist nicht zu erwarten, daß sie bessere Ergebnisse liefern.

Die in Kapitel 4.1 angeschnittene Frage nach der - mehr oder weniger vorhandenen - Vollständigkeit des Hypothesenraumes sollte ebenfalls anhand zusätzlicher Tests beantwortet werden.

4.2.2 Testverfahren

Das Lernverfahren wurde mit den schon aus Kapitel 3.3.2.3 bekannten und einigen weiteren Traces getestet. Bei den zusätzlichen Traces handelt es sich um Fahrten im gleichen Raum wie bei Trace 52 bzw. Trace 92.



Es werden für die einzelnen Traces jeweils zwei Tabellen angegeben. Die erste zeigt die Ergebnisse des Lernverfahrens inklusive der Ergebnisse für die Zwischenschritte. Aus Gründen der Übersichtlichkeit wird nicht der gesamte Parametersatz angegeben, sondern nur der Wert für die maximal erlaubte Differenz. Der doppelte Rahmen markiert die Ausgabe des Verfahrens. Die zweite Tabelle enthält die Ergebnisse für die zusätzlich getesteten Parametersätze.

Die geforderte minimale Übereinstimmung betrug jeweils 99%. Ob eine minimale Übereinstimmung von 99% oder von 100% gefordert wird, ist bei den meisten Traces egal, da diese hohen Werte normalerweise nicht erreicht werden. Das Verfahren wird aufgrund eines anderen Abbruchkriteriums die Suche beenden, etwa wenn ein Blatt des Suchbaumes erreicht ist. Bei den Traces, in denen der Roboter sich meistens parallel entlang einer angemessenen Kante bewegt, sieht das jedoch anders aus. Bei einer geforderten minimalen Übereinstimmung von 100% kann es passieren, daß ein schlechterer Parametersatz ausgewählt wird als bei einer geforderten minimalen Übereinstimmung von 99% (siehe dazu die Lernergebnisse zu Trace 55 und Trace 203 im folgenden Kapitel).

4.2.3 Testergebnisse

Trace 50

Lernergebnis:

max. erlaubte Differenz	Übereinstimmung	Anteil Intervalle mit Länge 1
16	87,03%	4,97%
8	90,76%	7,28%
4	93,28%	11,71%
6	90,88%	7,27%
5	91,96%	9,53%

Ergebnisse für die zusätzlich getesteten Parametersätze:

max. erlaubte Differenz	Übereinstimmung	Anteil Intervalle mit Länge 1
3	93,76%	12,68%
5,5	91,48	9,45%
7	90,88%	7,27%
9	89,56%	7,1%

Trace 90

Lernergebnis:

max. erlaubte Differenz	Übereinstimmung	Anteil Intervalle mit Länge 1
16	79,69%	7%
8	85,27%	11,56%
12	82,3%	7,79%
10	84,32%	8,31%
9	85,51%	10,69%

Ergebnisse für die zusätzlich getesteten Parametersätze:

max. erlaubte Differenz	Übereinstimmung	Anteil Intervalle mit Länge 1
7	85,99%	11,88%
9,5	85,39%	8,48%
11	83,85%	8,5%
13	79,1%	7,36%

Es fällt auf, daß der Parametersatz mit der maximal erlaubten Differenz von 10 einen etwas besseren Wert für die Übereinstimmung und entgegen der Wahrscheinlichkeit auch einen etwas besseren Wert für den Anteil der Intervalle mit Länge 1 hat.

Gemäß dem Kriterium, das in Kapitel 4.1 für die Entscheidung zwischen den beiden zuletzt betrachteten Parametersätzen angegeben wurde, wäre 9,5 noch etwas besser als 10.

Trace 52

Lernergebnis:

max. erlaubte Differenz	Übereinstimmung	Anteil Intervalle mit Länge 1
16	83%	1,46%
8	90,3%	2,21%
4	96,59%	16,98%
6	93,04%	3,34%
5	94,08%	4,92%

Bei dem Schritt von der maximal erlaubten Differenz 4 zu dem gemäß der Struktur des Hypothesenraumes nächstgenerelleren Wert 6 zeigt sich eine besonders deutliche Verringerung des Anteils der Intervalle der Länge 1.

Ergebnisse für die zusätzlich getesteten Parametersätze:

max. erlaubte Differenz	Übereinstimmung	Anteil Intervalle mit Länge 1
3	99,22%	29,37%
4,5	94,39%	8,2%
7	91,41%	2,33%
9	89,38%	2%

Auch die Auswahl einer maximal erlaubten Differenz von 4,5 als Lernergebnis wäre evtl. noch sinnvoll gewesen. Nach dem Kriterium, das in Kapitel 4.1 für die Entscheidung zwischen den beiden zuletzt betrachteten Parametersätzen angegeben wurde, würde jedoch den Parametersätzen mit der maximal erlaubten Differenz von 5 bzw. 6 der Vorzug gegeben.

Trace 92

Lernergebnis:

max. erlaubte Differenz	Übereinstimmung	Anteil Intervalle mit Länge 1
16	81,12%	1,52%
8	91,21%	3,05%
4	95,95%	21,52%
6	93,09%	5,24%
5	93,41%	9,45%

Hier wird die Qualität des Resultates im Vergleich zu den benachbarten Werten 4 und 5 besonders deutlich: Das Lernergebnis weist einen wesentlich geringeren Anteil an Intervallen der Länge 1 auf, aber nur einen geringfügig kleineren Wert für die Übereinstimmung mit den Sensormusterbeispielen.

Ergebnisse für die zusätzlich getesteten Parametersätze:

max. erlaubte Differenz	Übereinstimmung	Anteil Intervalle mit Länge 1
3	96,46%	35,58%
5,5	93,42%	6,66%
7	92,01%	4,21%
9	88,64%	3,1%

Trace 54

Lernergebnis:

max. erlaubte Differenz	Übereinstimmung	Anteil Intervalle mit Länge 1
16	89,56%	2,98%
8	91,78%	4,84%
4	91,78%	7,75%

Ergebnisse für die zusätzlich getesteten Parametersätze:

max. erlaubte Differenz	Übereinstimmung	Anteil Intervalle mit Länge 1
5	91,78%	6,78%
6	91,78%	4,84%
7	91,78%	4,84%
9	91,11%	4,63%
10	90,89%	9,41%
11	90,44%	3,69%

Trace 94

Lernergebnis:

max. erlaubte Differenz	Übereinstimmung	Anteil Intervalle mit Länge 1
16	88,41%	3,4%
8	91,85%	6,07%
4	91,85%	9,11%

Bei Trace 94 wie auch bei Trace 54 würden ohne die Bedingung, daß das Verfahren abbricht, sobald sich die Übereinstimmung nicht mehr ändert, noch weitere Parametersätze ausprobiert. Bei Trace 94 sind das diejenigen mit den maximal erlaubten Differenzen 6 bzw. 5. Die Übereinstimmung ändert sich auch dabei nicht, der Anteil der Intervalle mit Länge 1 fällt zunächst wieder auf 6,07% und steigt bei einer Differenz von 5 auf 7,01%. Bei Trace 54 wären es die Parametersätze mit den maximal erlaubten Differenzen 2 bzw. 3. Die Übereinstimmung ändert sich ebenfalls nicht, der Anteil der Intervalle mit Länge 1 wächst jedoch auf 9,93% und fällt bei einer Differenz von 3 wieder auf 8,72%.

Ergebnisse für die zusätzlich getesteten Parametersätze:

max. erlaubte Differenz	Übereinstimmung	Anteil Intervalle mit Länge 1
5	91,85%	7,01%
6	91,85%	6,07%
7	91,85%	6,07%
9	90,56%	5,92%
10	90,13%	5%
11	89,27%	3,85%

Sowohl bei Trace 94 als auch bei Trace 54 wurden für die maximal erlaubten Abweichungen 6, 7 und 8 identische Sequenzen von Basiswahrnehmungsmerkmalen generiert.

In beiden Fällen wurde kein zusätzlicher Parametersatz mit einem um 0,5 geänderten Wert für die erlaubte Differenz getestet, da sich auch bei größeren Schritten nur geringe Veränderungen der Werte für Übereinstimmung und Anteil der Intervalle mit Länge 1 ergeben.

Trace 55

Lernergebnis:

max. erlaubte Differenz	Übereinstimmung	Anteil Intervalle mit Länge 1
16	89,69%	0,74%
8	96,01%	1,96%
4	98,12%	3,5%
2	99%	8,85%

Bei einer geforderten minimalen Übereinstimmung von 100% wäre zusätzlich noch der Parametersatz mit der maximal erlaubten Differenz 1 getestet worden. Die mit diesem Parametersatz generierten Basiswahrnehmungsmerkmale erreichen eine Übereinstimmung von 99,45%, der Anteil der Intervalle der Länge 1 liegt jedoch bei 19,18%. Die Werte für den Parametersatz mit der maximal erlaubten Differenz 4 sind also nach dem Kriterium, das für die Entscheidung zwischen den beiden zuletzt betrachteten Parametersätzen angegeben wurde, besser als die für die Differenzen 1 und 2. Da jedoch nur der Vergleich zwischen den letzten beiden Parametersätzen vorgesehen ist, würde der bessere Parametersatz nicht mehr in Betracht gezogen. Ausgewählt würde der Parametersatz mit der maximal erlaubten Differenz 2.

In Erwägung zu ziehen ist natürlich auch, nicht nur die zwei zuletzt betrachteten Parametersätze zu vergleichen, sondern die drei zuletzt betrachteten Parametersätze. Dann würde auch bei einer geforderten minimalen Übereinstimmung von 100% der Parametersatz mit der maximal erlaubten Differenz 4 ausgewählt.

Ergebnisse für die zusätzlich getesteten Parametersätze:

max. erlaubte Differenz	Übereinstimmung	Anteil Intervalle mit Länge 1
1	99,45%	19,18%
3	98,89%	4,15%
3,5	99%	4,26%
5	97,67%	2,84%

Eine maximal erlaubte Differenz von 3, 3,5 und 5 wäre gemäß dem Kriterium, das für den Vergleich der beiden zuletzt betrachteten Parametersätze vorgesehen ist, geringfügig besser als 4.

Trace 95

Lernergebnis:

max. erlaubte Differenz	Übereinstimmung	Anteil Intervalle mit Länge 1
16	85,71%	2,18%
8	88,57%	5,58%
4	93,96%	10,53%
6	91,1%	6,39%
5	93,52%	9,52%

Ergebnisse für die zusätzlich getesteten Parametersätze:

max. erlaubte Differenz	Übereinstimmung	Anteil Intervalle mit Länge 1
3	94,4%	11,53%
5,5	92,2%	8,58%
7	89,56%	5,89%
9	88,24%	4,86%

Trace 203

Lernergebnis:

max. erlaubte Differenz	Übereinstimmung	Anteil Intervalle mit Länge 1
16	95,58%	1,94%
8	97,56%	3,15%
4	97,63%	5,21%
2	99,37%	8,93%

Wie bei Trace 55 wäre bei einer geforderten minimalen Übereinstimmung von 100% auch hier noch der Parametersatz mit der maximal erlaubten Differenz 1 getestet worden. Die mit diesem Parametersatz generierten Basiswahrnehmungsmerkmale erreichen eine Übereinstimmung von 99,8%, der Anteil der Intervalle der Länge 1 liegt bei 14,26%. Auch hier ist der Parametersatz mit der maximal erlaubten Differenz 4 gemäß dem Kriterium für die Entscheidung zwischen den beiden zuletzt betrachteten Parametersätzen besser als die Parametersätze für die Differenzen 1 und 2. Ausgewählt würde bei einer geforderten minimalen Übereinstimmung von 100% jedoch der Parametersatz mit der maximal erlaubten Differenz 2.

Wie bei Trace 55 würde auch hier bei einer geforderten minimalen Übereinstimmung von 100% und dem Vergleich der drei zuletzt betrachteten Parametersätze der Parametersatz mit der maximal erlaubten Differenz 4 ausgewählt.

Ergebnisse für die zusätzlich getesteten Parametersätze:

max. erlaubte Differenz	Übereinstimmung	Anteil Intervalle mit Länge 1
1	99,8%	14,26%
2,5	99,37%	7,9%
3	98,03%	6,48%
5	97,63%	4,85%

Auch eine maximal erlaubte Differenz von 2,5, 3 und 5 wäre nach dem üblichen Kriterium geringfügig besser gewesen als 2.

4.2.4 Analyse

1) Die Testergebnisse dokumentieren, daß die Wahl einer erlaubten Differenz von 16 als Startwert für die Suche im Hypothesenraum sinnvoll ist, denn erst ab diesem Wert für die maximal erlaubte Differenz werden in der Regel Sequenzen von Basiswahrnehmungsmerkmalen generiert, die eine akzeptable Übereinstimmung mit den Sensormusterbeispielen aufweisen. Lediglich Trace 203 bildet eine Ausnahme unter den getesteten Traces: bei einer maximal erlaubten Differenz von 32 wird bereits eine Übereinstimmung von 87,97% erreicht. Sinnvoll ist der Beginn der Suche mit einem größeren Wert für die erlaubte Differenz - z.B. 32 - nur in sehr seltenen Fällen:

- Falls die Sequenzen von Basiswahrnehmungsmerkmalen bei einer maximal erlaubten Differenz von 16 schon zu speziell sind,
- die geforderte Übereinstimmung sowohl bei 16 als auch bei 32 erreicht wird

und

- aufgrund von Übereinstimmung und Anteil der Intervalle der Länge 1 der Parametersatz mit dem Wert 32 ausgewählt würde,

wäre die Lösung 32 schneller gefunden worden, wenn die Suche bei dieser maximal erlaubten Differenz begonnen hätte.

2) Obwohl das Verfahren zur Generierung der Basiswahrnehmungsmerkmale nicht die in Kapitel 3.3.1 geforderte Eigenschaft besitzt, die geordnete Menge der Parametersätze auf die geordnete Menge der Sequenzen von Basiswahrnehmungsmerkmalen abzubilden, zeigten bereits die Tests in Kapitel 3.3.3, daß ein restriktiverer Parametersatz meistens für eine größere Übereinstimmung der generierten Sequenzen von Basiswahrnehmungsmerkmalen mit den Sensormusterbeispielen und für einen größeren Anteil an Intervallen der Länge 1 sorgt. Die Annahme, daß ein Lernverfahren diese Abhängigkeit nutzen sollte, wenn auch keine Garantie für den Erfolg besteht, wurde durch die im vorherigen Kapitel dargestellten Ergebnisse eindrucksvoll bestätigt. Der Algorithmus lieferte fast immer den besten Parametersatz, in den übrigen Fällen immerhin einen sehr guten. Lediglich bei den Traces 90, 55 und 203 gab es geringfügig geeignetere Parametersätze. Obwohl es sich dabei z.T. um Parametersätze mit einem um

0,5 geänderten Wert für die erlaubte Differenz handelte, scheint der Nutzen einer Ergänzung des Hypothesenraumes um solche Parametersätze doch zu gering zu sein. Die Basiswahrnehmungsmerkmale haben zwar einen großen Einfluß auf die Regeln für die abstrakteren Begriffe. Ebenso beeinflussen aber auch die übrigen Lernschritte auf der Seite der Wahrnehmungen wie auf der Handlungsseite die Qualität der Regeln für operationale Konzepte. Anzunehmen ist, daß der Einfluß der Basiswahrnehmungsmerkmale doch zu gering ist, als daß sich durch geringfügige Verbesserungen der Basiswahrnehmungsmerkmale wesentliche Verbesserungen bei den Regeln für operationale Konzepte ergeben könnten.

Bei den Ergebnissen für Trace 55 und Trace 203 (Kapitel 4.2.3) wurde bereits erwähnt, daß bei einer geforderten Übereinstimmung von 100% das gleiche Lernergebnis erzielt worden wäre, wenn die letzten drei - statt nur die letzten zwei - Parametersätze verglichen worden wären. Ist es sinnvoll, das Lernverfahren entsprechend zu verändern? Bei den übrigen Traces hätte eine höhere geforderte Übereinstimmung die Resultate nicht verändert. Das ist wohl von den meisten Traces zu erwarten, denn auch eine Übereinstimmung von 99% wird nur erreicht bei Roboterfahrten mit bestimmten Eigenschaften, wie sie bereits in Kapitel 3.3.4 1) genannt wurden. Zudem müßte der Vergleich der letzten drei Parametersätze in jedem Fall durchgeführt werden, ist aber nur in den seltenen Fällen nötig, wenn eine Übereinstimmung von mindestens 99% erreicht wird. Da die geringere geforderte minimale Übereinstimmung also das gleiche leistet und einen geringeren Aufwand erfordert, sollte das ursprünglich vorgestellte Verfahren beibehalten werden.

Zusammenfassend läßt sich sagen, daß der in Kapitel 4.1 beschriebene Algorithmus zum Lernen eines geeigneten Parametersatzes für die Generierung der Basiswahrnehmungsmerkmale eines Trace sehr gute Resultate liefert. Die unterschiedlichen Ergebnisse für den am besten geeigneten Parametersatz bei den einzelnen Traces verdeutlichen jedoch auch die beschränkte Vorhersagekraft eines Lernergebnisses für andere Traces.

Das führt zu folgenden Problemen bei der Auswahl eines Parametersatzes in der Anwendungsphase: Grundsätzlich gilt natürlich, daß der gleiche Parametersatz verwendet werden muß, der in der Lernphase ausgewählt wurde. Nehmen wir an, es sollen Regeln für den operationalen Begriff „an einer Tür vorbeifahren“ gelernt werden. Damit diese Regeln nicht zu speziell werden, müssen in der Lernphase mehrere Traces durchgeführt werden, jeweils in einem anderen Abstand zur Tür. Wenn das Lernverfahren nun für die Traces unterschiedliche Ergebnisse liefert, welchen Parametersatz soll man dann in der Anwendungsphase verwenden? Die gleiche Frage stellt sich, wenn die Regeln für mehrere operationale Begriffe angewendet werden müssen. So erfordert etwa die Anweisung an den Roboter „Gehe durch die Tür“ zunächst das Aufspüren der Tür. Dazu wird er eine Wand suchen und sich an ihr entlang bewegen, bis er die Regel für „an einer Tür vorbeifahren“ anwenden kann. (Genau das passiert bei Trace 203, siehe Kapitel 3.3.2.3, Abbildung 13.) Erst dann kann die Regel für „durch die Tür fahren“ angewendet werden. Welchen Parametersatz wählt man nun - einen für „an einer

Tür vorbeifahren“ geeigneten oder einen, der für „durch die Tür fahren“ gelernt wurde?

Die beste Lösung wäre natürlich, während einer Fahrt des Roboters den für die Verarbeitung der Sensordaten zu verwendenden Parametersatz an die jeweilige Situation anzupassen. Das setzt jedoch voraus, daß der Roboter die Situation erkennt. Wenn er sie aber erkennt, besteht keine Notwendigkeit, den Parametersatz zu ändern. Umgekehrt wird er bei Verwendung eines ungeeigneten Parametersatzes nicht in der Lage sein zu entscheiden, welcher Parametersatz in der aktuellen Situation geeignet wäre. Bei der gesamten Fahrt müssen also die Meßdaten mit dem gleichen Parametersatz verarbeitet werden.

Es liegt nahe, den speziellsten aller gelernten Parametersätze zu verwenden. Es können dann natürlich Situationen vorkommen, in denen die generierten Sequenzen so speziell sind, daß sie zum Lernen nicht mehr geeignet wären. Bei der Anwendung der Regeln hat das jedoch lediglich die Konsequenz, daß die Zeiträume der Basiswahrnehmungsmerkmale in der Regel kleiner sind als es mit dem optimal geeigneten Parametersatz der Fall wäre. Im Idealfall würden mit dem spezielleren Parametersatz die gleichen Basiswahrnehmungsmerkmale erzeugt wie mit dem optimal geeigneten, so daß die gleichen Regeln für operationale Konzepte angewandt werden können. Der speziellere Parametersatz würde aber für mehrere kleinere Basiswahrnehmungsmerkmale mit dem gleichen Merkmalsymbol sorgen. Beispielsweise könnte das Basiswahrnehmungsmerkmal

increasing(t102,92,s4,10,45,24),

das vom optimal geeigneten Parametersatz generiert wurde, von einem spezielleren Parametersatz aufgespalten werden in

increasing(t102,92,s4,10,15,19),

increasing(t102,92,s4,15,28,23),

*increasing(t102,92,s4,28,43,25)*³⁷.

Die Generierung kürzerer Basiswahrnehmungsmerkmale hat den Vorteil, daß die Information über die Wahrnehmung früher für die Navigation verfügbar ist. Das ist wichtig, beispielsweise wenn sich der Roboter parallel an einer Wand entlang bewegen soll. Ob er wirklich diese Bewegung ausführt, muß anhand eines Basiswahrnehmungsmerkmals überprüft werden. Solange er jedoch Distanzen mißt, die sich relativ gleichmäßig verändern, wird das aktuelle Zeitintervall bei einem nicht allzu speziellen Parametersatz weiter fortgesetzt. Bevor das Intervall nicht beendet und das Basiswahrnehmungsmerkmal ausgegeben wird, ist nicht bekannt, ob sich der Roboter tatsächlich parallel an einer Wand entlang bewegt oder aber sich langsam von ihr weg bewegt oder direkt auf sie zu fährt etc.. In diesem Fall sorgt auch die inkrementelle Verarbeitung der Meßdaten nicht dafür, daß der Roboter sofort angemessen reagieren kann. Ein sofortiges Reagieren auf Wahrnehmungen ist natürlich möglich, aber die Wahrnehmung ist eben erst nach Beendigung eines Zeitintervalls für die Navigation verfügbar.

37 Hier ist nicht das systematische Aufspalten nötig, das in Kapitel 3.3.2.2 beschrieben wurde, denn es geht in der Anwendungsphase nicht mehr um einen Vergleich mit Sensormusterbeispielen.

Die Verwendung eines sehr speziellen Parametersatzes - häufig also eines anderen als den zum Lernen des jeweiligen operationalen Konzeptes verwendeten - birgt allerdings grundsätzlich die Gefahr, daß eine Sequenz von Basiswahrnehmungsmerkmalen mit anderen Merkmalssymbolen erzeugt wird. Das kann passieren, wenn sich ein Intervall-Winkel gerade so verändert, daß er in den Bereich für ein anderes Merkmalssymbol fällt³⁸. Durch diese Veränderung ist möglicherweise eine Regel für ein Sensormuster nicht mehr anwendbar, und das gleiche gilt eventuell auch für Regeln für noch abstraktere Begriffe. Schlimmstenfalls fährt der Roboter dann an einer Tür vorbei ohne sie zu erkennen, da die gelernten Regeln für den operationalen Begriff „an einer Tür vorbeifahren“ nicht mehr angewendet werden können. Glücklicherweise ist das Auftreten dieses Falles unwahrscheinlich, denn es gibt in Relation zur Anzahl möglicher Intervall-Winkeln nur sehr wenige Bereichsgrenzen, bei deren Überschreitung dann ein anderes Merkmalssymbol zugewiesen würde (siehe Kapitel 3.2.1.1).

Verwendet man in der Anwendungsphase stets den speziellsten gelernten Parametersatz, ist es trotzdem noch möglich, daß ein Basiswahrnehmungsmerkmal einen sehr großen Zeitraum abdeckt und die für die Navigation nötige Information erst sehr spät zur Verfügung steht. Wenn die gemessenen Distanzen sich dermaßen gleichmäßig verändern, daß auch bei einem sehr restriktiven Parametersatz ein sehr langes Basiswahrnehmungsmerkmal entsteht, ist eine Begrenzung der Zeitintervalllänge für die Basiswahrnehmungsmerkmale sinnvoll. Diese maximal erlaubte Intervalllänge ist ein Parameter, der zusätzlich zu den in Kapitel 3.2.2.2 beschriebenen Parametern angegeben werden kann³⁹. Ein Zeitintervall wird dann auf jeden Fall - also unabhängig von der Differenz zwischen dem aktuellen Winkel und dem Intervall-Winkel - bei Überschreiten der vorgegebenen maximalen Intervalllänge beendet. Dieses Vorgehen birgt natürlich die gleiche Gefahr wie die Verwendung eines ungeeigneten Parametersatzes. Die Generierung einer Sequenz von Basiswahrnehmungsmerkmalen mit anderen Merkmalssymbolen ist jedoch - wie schon gesagt - unwahrscheinlich.

Eine zusätzliche Möglichkeit, die negativen Folgen eines unpassenden Parametersatzes auszugleichen, besteht im Ausnutzen des „Trennsignals“, auf das schon in Kapitel 3.3.4 hingewiesen wurde. Hier geht es natürlich nicht mehr um das Erreichen einer möglichst großen Übereinstimmung mit den Sensormusterbeispielen, was in der Lernphase wichtig ist. In der Anwendungsphase bewirkt ein häufiges, kurzes Stehenbleiben des Roboters,

38 Möglich ist das natürlich auch, wenn der verwendete Parametersatz in der jeweiligen Situation zu generell ist.

39 Diese Möglichkeit ist implementiert, sie wurde in Kapitel 3.2.2.2 jedoch nicht dokumentiert. Die Verwendung dieses zusätzlichen Parameters ändert nichts am Ergebnis der Analyse in Kapitel 3.3.4!

Setzt man den Parameter auf einen sehr hohen Wert - für die zum Testen verwendeten Traces reicht 100, hat er keinerlei Einfluß auf die erzeugten Sequenzen von Basiswahrnehmungsmerkmalen. In der Anwendungsphase könnte man einen kleinen Wert wählen in Abhängigkeit vom zeitlichen Abstand der Sensormessungen und vom Zeitraum, nach dem die Information über die Wahrnehmung spätestens verfügbar sein soll.

daß sich Fehler bei der Entscheidung über die Beendigung eines Intervalls nicht aufsummieren. Dadurch steigt die Wahrscheinlichkeit, auch bei ungeeignetem Parametersatz die Kantenwechsel aufzuspüren, die bei Verwendung des gelernten Parametersatzes erkannt worden wären.

5 Schlußbetrachtungen

In der vorliegenden Diplomarbeit wurde ein Verfahren vorgestellt, das numerische Sensordaten eines mobilen Roboters zu einer Sequenz qualitativer Merkmale (Basiswahrnehmungsmerkmale) verarbeitet, womit ein *signal-to-symbol*-Problem gelöst wurde.

Aus der Einbindung der Diplomarbeit in das Forschungsprojekt B-Learn II⁴⁰ ergaben sich folgende Anforderungen an ein Verfahren, das Basiswahrnehmungsmerkmale aus numerischen Werten generiert:

- Das Verfahren mußte sowohl in der Lernphase wie auch in der Anwendungsphase angewendet werden können. Da die Meßdaten aber nur in der Lernphase mit einer Klassifikation versehen sind, konnte diese Klassifikation für die Generierung der Basiswahrnehmungsmerkmale nicht benutzt werden. Lernen aus Beispielen war somit nicht möglich.

Das hier neu entwickelte Verfahren benötigt keine Klassifikation der Eingabedaten.

- Ein Raum besteht im vorgegebenen Szenario aus verschiedenen Objekten: Wänden, Türen und Schränken. Das Verfahren mußte die Voraussetzungen dafür schaffen, daß der Roboter auf seiner Fahrt durch den Raum die einzelnen Objekte unterscheiden kann.

Das im Rahmen dieser Diplomarbeit präsentierte Verfahren zur Verarbeitung von Robotersensordaten gewährleistet durch ein Zusammenfassen ähnlicher Meßdaten die Grundvoraussetzung. Der hier entwickelte Lernalgorithmus sorgt dafür, daß die Zusammenfassung geeignet ist für die nächsten Lernschritte und schafft damit eine Voraussetzung, schließlich operationale Begriffe lernen zu können.

- In der Anwendungsphase muß der Roboter sofort auf Wahrnehmungen reagieren können. Um das zu ermöglichen, mußte die Verarbeitung inkrementell erfolgen.

Im Gegensatz zu allgemein gebräuchlichen Methoden zum Zusammenfassen von Daten erfüllt das hier vorgestellte Verfahren diese strenge Anforderung.

- Das Verfahren hatte die zeitliche Abfolge der Meßdaten zu berücksichtigen. Diese Forderung wird durch die streng inkrementelle Verarbeitung erfüllt.

Die Qualität der Basiswahrnehmungsmerkmale hat einen großen Einfluß auf die Qualität der Regeln für operationale Begriffe. Um eine hohe Qualität der Basiswahrnehmungsmerkmale zu erreichen, wurden verschiedene Verarbeitungsverfahren auf ihre Eignung hin untersucht. Diese Verfahren unterscheiden sich durch die Vorgabe bestimmter Parameter. Ein Teil der Parameter bestimmt die grundlegende Strategie bei der Verarbeitung, ein anderer

⁴⁰ Förderung: ESPRIT P 7274, Land NRW

Teil legt die Einzelheiten fest. Anhand von Tests wurde ermittelt, daß die einfachste grundlegende Strategie am besten geeignet ist, die Meßdaten zusammenzufassen. Dabei wird lediglich die Differenz einer Sensormessung zum Mittelwert bereits zusammengefaßter Sensormessungen berücksichtigt.

Für die Auswahl eines Parameters, der die Einzelheiten der Verarbeitung festlegt, wurde ein Lernalgorithmus vorgestellt. Er führt eine heuristische Suche in einem halbgeordneten und geeignet strukturierten Hypothesenraum von Parametersätzen durch, die diese einfachste grundlegende Strategie repräsentieren. Der Lernalgorithmus erhält Basiswahrnehmungsmerkmale als Eingabe und bewertet sie. In Abhängigkeit von der Bewertung wählt er einen neuen Parametersatz für die abermalige Generierung von Basiswahrnehmungsmerkmalen, oder er gibt die Basiswahrnehmungsmerkmale aus. Dieses Verfahren kann man als „kleine Lernschleife“ bezeichnen.

Diese kleine Lernschleife ist ein Spezialfall des Lernens aus Beobachtungen. Als Eingaben für das Verfahren zur Generierung der Basiswahrnehmungsmerkmale stehen lediglich Beobachtungen in Form von Meßdaten zur Verfügung, die ein mobiler Roboter bei einer Fahrt durch einen Raum liefert. Bei der Bewertung der Basiswahrnehmungsmerkmale durch den Lernalgorithmus wird jedoch indirekt die Klassifikation einbezogen, die ja in der Lernphase gegeben ist. Durch die indirekte Berücksichtigung der Klassifikation wird die Voraussetzung für das Lernen der Wahrnehmungsmerkmale der nächsthöheren Abstraktionsstufe geschaffen.

Die Tests mit den verschiedenen Varianten des Verfahrens zur Verarbeitung der Sensordaten ließen nicht nur Rückschlüsse auf eine geeignete grundlegende Strategie zu. Eine Analyse der Testergebnisse ergab weitere wichtige Punkte:

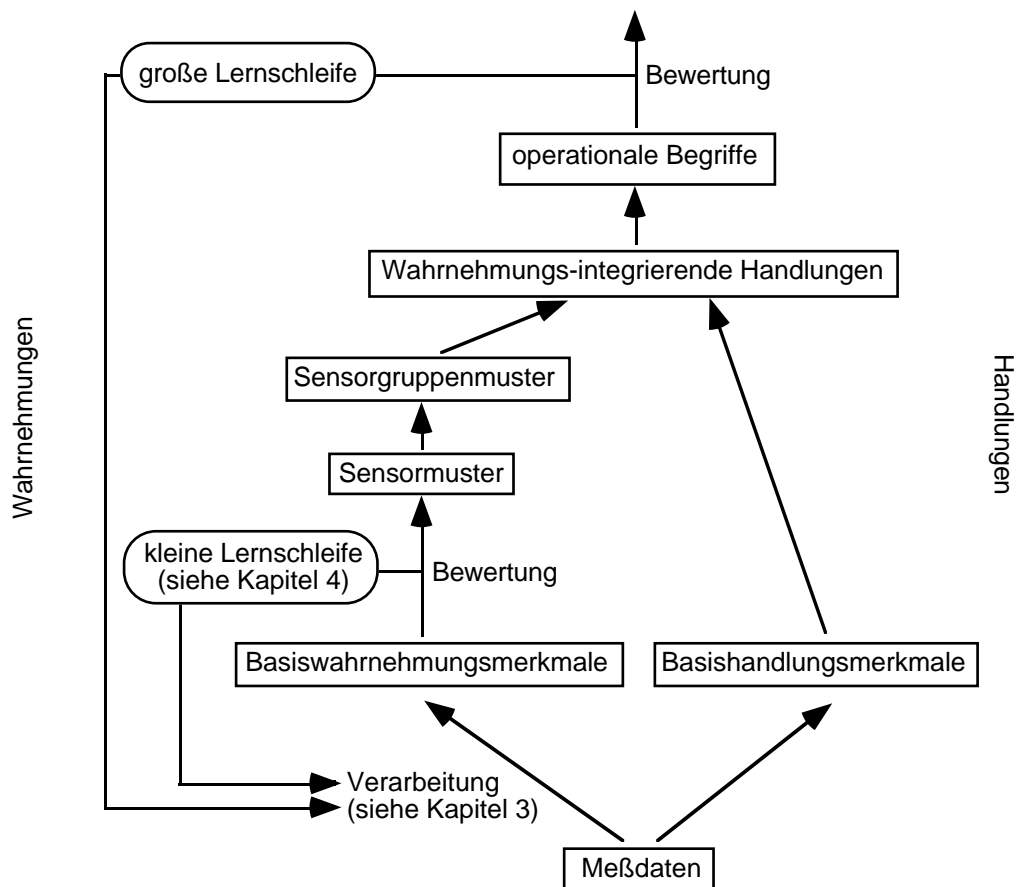
- Ein Wechsel der vom Sensor angemessenen Kante ist bei konvexen und konkaven Ecken nicht mit ausreichend großen Änderungen der gemessenen Distanzen korreliert. Für Sensormuster *s_line*, aus denen das Sensormuster für konvexe bzw. konkave Ecken - *s_convex* bzw. *s_concave* - gebildet wird, gibt es daher keine passenden Basiswahrnehmungsmerkmale. Somit können auch keine Regeln gelernt werden, und die Verwendung des Sensormusters *s_line* erübrigt sich in diesen Fällen.
- Es ist nicht möglich, eine Halbordnung auf Parametersätzen zu definieren, so daß bei einer Suche im halbgeordneten Hypothesenraum garantiert werden kann, den besten Parametersatz zu finden.

Dieses Analyseergebnis gilt für eine ganze Klasse neuer Verfahren - nicht nur für die getesteten Varianten des Verfahrens zur Generierung der Basiswahrnehmungsmerkmale, sondern auch für alle Varianten, die man sich zusätzlich ausdenken könnte. Diese Klasse von Verfahren ist dadurch gekennzeichnet, daß von Kriterien für die Beendigung eines Zeitintervalls geschlossen wird auf die Länge der entstehenden Zeitintervalle. Die Länge der Zeitintervalle war durch das Szenario als Qualitätskriterium für die Basiswahrnehmungsmerkmale vorgegeben.

Tests mit dem Lernalgorithmus belegten, daß es trotz des letztgenannten Analyseergebnisses sinnvoll ist, eine heuristische Suche in einem halbgeordneten und

geeignet strukturierten Hypothesenraum von Parametersätzen durchzuführen: Der Lernalgorithmus wählte stets sehr gut geeignete Parametersätze aus. Die Tests zeigten allerdings auch die mangelnde Übertragbarkeit des Lernergebnisses. Die Vorhersagekraft eines gelernten Parametersatzes ist daher nur gering: bei anderen Meßdaten als Eingabe wird oft auch ein anderer Parametersatz gelernt. Daraus ergeben sich bei der Anwendung der gelernten Regeln Probleme: Welchen der gelernten Parametersätze sollte man für die Verarbeitung der Sensordaten wählen? Wie geht man mit den Folgen eines in vielen Situationen ungeeigneten Parametersatzes um? Als Lösungsvorschlag wurde genannt, den speziellsten aller gelernten Parametersätze zu verwenden, die Länge der Basiswahrnehmungsmerkmale zu begrenzen und ein „Trennsignal“ einzusetzen, indem der Roboter während seiner Fahrt des öfteren kurze Zeit stehen bleibt.

Neben der kleinen Lernschleife wäre auch noch eine große Lernschleife denkbar. Dabei würden ausgehend von den Basiswahrnehmungsmerkmalen alle weiteren Lernschritte ausgeführt wie in Kapitel 1 skizziert. Bewertet würde schließlich die Qualität der Regeln für operationale Konzepte. Sind die Regeln gut genug, bräche die Schleife ab, andernfalls müßte noch ein anderer Parametersatz gewählt werden, mit dem dann neue Basiswahrnehmungsmerkmale generiert würden.



Die Qualität der Regeln würde bei einer großen Schleife nicht nur von den Basiswahrnehmungsmerkmalen beeinflusst. Einflußfaktoren sind beispielsweise auch die Regelmodelle und die verschiedenen Parameter, die RDT vorgegeben werden, und die Auswahl abstrakterer Wahrnehmungsmerkmale. Zudem wird für das Lernen der abstrakteren Begriffe deutlich mehr Zeit benötigt als für den in Kapitel 4 vorgestellten Lernalgorithmus. Daher sollte diese große Lernschleife erst dann durchgeführt werden, wenn die kleine Lernschleife mehrmals durchlaufen wurde und damit bereits ein hohes Qualitätsniveau der Basiswahrnehmungsmerkmale vorausgesetzt werden kann.

Wie der Parametersatz im Fall ungenügender Qualität der gelernten Regeln für operationale Konzepte verändert werden sollte, könnte Gegenstand zukünftiger Untersuchungen sein. Denkbar wäre z.B., innerhalb der großen Schleife die Grenze für die Einstufung einer Sequenz von Basiswahrnehmungsmerkmalen als „zu speziell“ zu verändern.

Ebenso müßte in Zukunft durch Tests mit dem Roboter noch überprüft werden, ob die Lösungsvorschläge im Zusammenhang mit der Auswahl eines Parametersatzes für die Anwendungsphase zum gewünschten Ergebnis führen. Eine weitere zukünftige Aufgabe besteht darin, das hier vorgestellte Verfahren mit neuen Traces zu testen, die nur die Meßdaten für ein Objekt oder eine

Kantenkonfiguration enthalten. Die Übertragbarkeit des Ergebnisses beim Lernen eines geeigneten Parametersatzes wird dadurch möglicherweise verbessert.

Im Rahmen einer anderen Diplomarbeit wird zur Zeit nach neuen sinnvolleren Sensormustern gefahndet. Daraus ergibt sich wiederum die Aufgabe, zu überprüfen, ob das hier vorgestellte Verfahren zusammen mit den neuen Sensormustern noch bessere Ergebnisse liefert.

Nachdem nun Möglichkeiten der Erweiterbarkeit dieser Diplomarbeit dargestellt worden sind, soll auch noch ihre Übertragbarkeit aufgezeigt werden.

Der Kern des hier vorgestellten Verfahrens zum Zusammenfassen von Meßdaten kann nicht nur eingesetzt werden wie bisher dargestellt. Denkbar ist ebenso der Einsatz als Methode zur Vorverarbeitung der Eingabedaten beispielsweise für ein Verfahren, das Entscheidungsbäume lernt. In Kapitel 2.3 wurde ja bereits darauf hingewiesen, daß als Vorverarbeitung meist eine statische Diskretisierung stetiger Attributwerte erforderlich ist.

Angesichts der umfangreichen Fallunterscheidung in Kapitel 3.2.2 ist diese Einsatzmöglichkeit leicht zu übersehen. Die zahlreichen zu unterscheidenden Fälle resultieren jedoch schlicht und einfach aus dem Anwendungsbereich in der Robotik. Wenn die Aufgabe nicht mehr darin besteht, relevante Wahrnehmungsmerkmale für die Navigation eines Roboters bereitzustellen, sondern stetige Werte für ein Attribut sinnvoll zu diskretisieren, fallen diese Sonderfälle weg. Außerdem müssen auch keine Winkel mehr berechnet werden. Das Ziel der Winkelberechnung war ja, nur die Änderungen der gemessenen Distanzen zu erfassen. Die Größe der gemessenen Distanz war dagegen nicht von Bedeutung. Im Gegensatz dazu geht es bei der Diskretisierung um die Größe eines Attributwertes und nicht um die Änderungen aufeinanderfolgender Attributwerte.

Die zu diskretisierenden Attributwerte müssen wie üblich zunächst sortiert werden⁴¹. Die sortierten Werte werden dann inkrementell zu Intervallen zusammengefaßt, wie es für die Sensormessungen beschrieben wurde: Für jeden Attributwert wird die Differenz zum Mittelwert bereits zusammengefaßter Attributwerte berechnet. Ist die maximal erlaubte Differenz überschritten, wird das aktuelle Intervall beendet. Andernfalls wird der aktuelle Attributwert dem Intervall hinzugefügt und der neue Mittelwert berechnet. Die Mittelwerte der Intervalle sind dann die gesuchten diskreten Attributwerte, die als Eingabe für das Verfahren dienen, das beispielsweise Entscheidungsbäume lernt.

Voraussetzung für eine gute Diskretisierung ist die Auswahl eines geeigneten Wertes für die maximal erlaubte Differenz. Bei der Anwendung, die in dieser Arbeit vorgestellt wurde, richtete sich die Bewertung der erzeugten Basiswahrnehmungsmerkmale nach den Erfordernissen des nächsten Lernschrittes. Entsprechend müßte die Qualität der erreichten Diskretisierung daran gemessen werden, welche Eingaben für das - um beim Beispiel zu bleiben -

41 Bevor das hier vorgestellte inkrementelle Verfahren zum Zusammenfassen der Attributwerte angewendet werden kann, müssen also alle Daten bekannt sein. Damit ist das gesamte Verfahren zur Diskretisierung nicht mehr inkrementell. Das ist jedoch irrelevant, da es hier nicht mehr um das sofortige Weiterverarbeiten der Daten geht.

Entscheidungsbaumlernverfahren besonders gut geeignet sind. Das entspricht auch der Forderung, die Rao und Lu an Diskretisierungsverfahren stellen (siehe Kapitel 2). Das in Kapitel 4 vorgestellte Lernverfahren ist dann derart zu modifizieren, daß statt der Übereinstimmung mit den Sensormusterbeispielen und des Anteils sehr kurzer Intervalle ein Qualitätskriterium für die Diskretisierung überprüft wird. Dann könnte auch für die Diskretisierung ein geeigneter Parametersatz gelernt werden.

Eventuell kann man aber ein solches Qualitätskriterium gar nicht angeben. Es gibt jedoch auch noch eine andere Möglichkeit der Qualitätsüberprüfung: Man wählt einen Parametersatz für die Diskretisierung, lernt aus den Beispielen mit diskretisierten Attributwerten einen Entscheidungsbaum und bewertet diesen dann. Je nachdem wie gut diese Bewertung ausfällt, wird dann entweder noch ein anderer Parametersatz ausprobiert oder eben nicht. Diese Bewertung hängt natürlich nicht nur von der Qualität des gewählten Parametersatzes ab, sondern auch von der Qualität des Verfahrens, das einen Entscheidungsbaum lernt. Wird das im Rahmen der Diplomarbeit entwickelte Verfahren angewendet, um eine gute Diskretisierung zu bestimmen, ist also auch wieder eine kleine und eine große Lernschleife möglich.

Das hier vorgestellte Verfahren vereint in sich die Vorteile der in Kapitel 2.3 vorgestellten Verfahren zur Vorverarbeitung stetiger Attributwerte z.B. für ein Entscheidungsbaum-lernverfahren. Die Methoden „gleiche Distanzen“ und „gleiche Häufigkeiten“ sind einfach und automatisch durchzuführen, sie berücksichtigen jedoch das Lernziel des Entscheidungsbaumverfahrens nicht. Das Verfahren von Lee und Shin berücksichtigt dagegen das Lernziel und ist automatisch zu realisieren, erfordert jedoch kompliziertere Berechnungen. Wendet man das hier neu entwickelte Verfahren für die Diskretisierung an, erhält man ein automatisch durchführbares Verfahren, das nur einfache Berechnungen benötigt und das Lernziel berücksichtigt.

Zum Abschluß möchte ich noch einmal zusammenfassen:

Ich habe in dieser Diplomarbeit ein Verfahren für die inkrementelle Verarbeitung numerischer Sensordaten zu qualitativen Wahrnehmungsmerkmalen entwickelt. Die Granularität der erzeugten Einteilung in Zeitintervalle wird dabei durch einen Lernalgorithmus bestimmt. Das Verfahren erfüllt sämtliche Bedingungen, die sich aus der Einbindung in das Projekt B-Learn II ergaben, und ist darüberhinaus erweiterbar durch eine größere Lernschleife.

Die Untersuchung des Verfahrens hat zwei Probleme deutlich gemacht:

- Die Sensormuster, die im Szenario vorgegeben wurden, sind zum Teil nicht geeignet, abstraktere Wahrnehmungen des Roboters zu repräsentieren.
- Es existiert keine Halbordnung auf Parametersätzen, die den Erfolg des Lernalgorithmus garantiert.

Daher sollte das Szenario noch einmal verändert werden. In einem geänderten Szenario finden sich dann möglicherweise neue Kriterien für die Qualität von Basiswahrnehmungsmerkmalen, so daß die gesuchte Halbordnung doch noch definiert werden könnte.

Der Kern meines Verfahrens ist so universell, daß er verwendet werden kann

- für einfache *signal-to-symbol*-Probleme
- zum Entdecken numerischer Regularitäten
- zur Analyse numerischer Daten - beispielsweise in Datenbanken - mit dem Ziel, qualitative Merkmale für diese Daten zu finden

und

- für die Diskretisierung stetiger Variablen - beispielsweise als Vorverarbeitung für ID3-ähnliche Verfahren

Danksagung

Danken möchte ich Katharina Morik für ihre konstruktive Kritik am Entwurf zur vorliegenden Arbeit und für ihre aufmunternden Worte in meiner Phase abgründiger Verzweiflung. Ebenso danke ich Joachim Hertzberg, Volker Klingspor und Hartmut Kreitlow für ihre hilfreichen Kommentare zum Entwurf. Schließlich sind auch noch die Diskussionen mit Anke Rieger und vor allem mit Volker Klingspor über ihre jeweiligen Arbeitsfelder im Projekt zu erwähnen, die dazu beitrugen, Zusammenhänge zu klären.

Literatur

- [Breiman et al. 1984] Breiman, L., Friedman, J.H., Olshen, R.A., Stone, C.J. (1984). *Classification and Regression Trees*. Wadsworth.
- [Bronstein et al. 1987] Bronstein, I.N., Semendjajew, K.A.; G. Grosche, V. Ziegler, D. Ziegler (Hrsg.) (1987). *Taschenbuch der Mathematik*. 23. Auflage. Teubner, Leipzig.
- [Connell und Mahadevan 1993] Connell, J.H., Mahadevan, S. (Hrsg.) (1993). *Robot learning*. Kluwer, Norwell, MA..
- [Dillmann et al. 1993] Dillmann, R., Kreuziger, J., Wallner, F. (1993). PRIAMOS - an experimental platform for reflexive navigation. In Groen, Hirose, Thorpe (Hrsg.) *IAS-3: Intelligent Autonomous Systems*. IOS Press.
- [Eadie et al. 1971] Eadie, W.T., Drijard, D., James, F.E., Roos, M., Sadoulet, B. (1971). *Statistical methods in experimental physics*. North-Holland.
- [Esposito et al. 1993] Esposito, F., Malerba D., Semeraro, G. (1993). Incorporating statistical techniques into empirical symbolic learning systems. In D.J. Hand (Hrsg.), *Artificial intelligence frontiers in statistics*: 168-181. Chapman & Hall, London.
- [Falkenhainer und Michalski 1986] Falkenhainer, B.C., Michalski, R.S. (1986). Integrating qualitative discovery: The ABACUS system. In *Machine Learning* 1 (4): 367-401
- [Friedman et al. 1977] Friedman, J.H., Bentley, J.L., Finkel, R.A. (1977). An algorithm for finding best matches in logarithmic expected time. In *ACM Transactions on Mathematical Software* 3 (3): 209-226.
- [Hartung et al. 1982] Hartung, J., Elpelt, B., Klösener, K.-H. (1982). *Statistik: Lehr- und Handbuch der angewandten Statistik*. Oldenbourg, München.
- [Henery 1994] Henery, R.J. (1994). Methods for Comparison. In D. Mitchie, D.J. Spiegelhalter, C.C. Taylor

[Kietz und Wrobel 1991]

(Hrsg.), *Machine learning, neural and statistical classification*, chapter 7: 107-125. Ellis Horwood, Englewood Cliffs, N.J..

Kietz, J.-U., Wrobel, S. (1991). Controlling the complexity of learning in logic through syntactic and task-oriented models. In S. Muggleton (Hrsg.), *Inductive Logic Programming*, chapter 16: 335-360. Academic Press, London.

- [Klingspor 1994] Klingspor, V. (1994). GRDT: Enhancing model-based learning for its application in robot navigation. In S. Wrobel (Hrsg.), *Proceedings of the 4th International Workshop on Inductive Logic Programming*, GMD-Studien Nr. 237: 107-122. St. Augustin.
- [Klingspor und Morik 1995] Klingspor, V., Morik, K. (1995). Towards concept formation grounded on perception and action of a mobile robot. In *Proceedings of the 4th International Conference on Intelligent Autonomous Systems* (im Druck)
- [Kokar 1986] Kokar, M.M. (1986). Discovering functional formulas through changing representation base. In *Proceedings of the 5th National Conference on Artificial Intelligence*: 455-459
- [Langley et al. 1983] Langley, P., Bradshaw, G.L., Simon, H.A. (1983). Rediscovering chemistry with the BACON system. In R.S. Michalski, J.G. Carbonell, T.M. Mitchell (Hrsg.), *Machine Learning: An artificial intelligence approach*. Volume 1, chapter 10: 307-329. Morgan Kaufmann, San Mateo, CA.
- [Langley und Michalski 1986] Langley, P., Michalski, R.S. (1986). Editorial: Machine learning and discovery. In *Machine Learning* 1: 363-366
- [Lee und Shin 1994] Lee, C., Shin, D.-G. (1994). A context-sensitive discretization of numeric attributes for classification learning. In Cohn, A. (Hrsg.) *Proceedings of the 11th European Conference on Artificial Intelligence*: 428-432
- [Mitchell 1982] Mitchell, T.M. (1982) Generalization as search. *Artificial Intelligence* 18 (2): 203-226.
- [Morik und Rieger 1993] Morik, K., Rieger, A. (1993). *Learning action-oriented perceptual features for robot navigation*. Forschungsbericht, Universität Dortmund.
- [Moulet 1994] Moulet, M. (1994). Iterative model construction with regression. In Cohn, A. (Hrsg.) *Proceedings of the 11th European Conference on Artificial Intelligence*: 448-452
- [Nordhausen und Langley 1993] Nordhausen, B., Langley, P. (1993). An Integrated Framework for Empirical Discovery. In *Machine Learning* 12: 17-47
- [Quinlan 1986] Quinlan, J.R. (1986). Induction of decision trees. In *Machine Learning* 1: 81-106

- [Rao und Lu 1992] Rao, R.B., Lu, S.C-Y. (1992). Learning Engineering Models with the Minimum Description Length Principle. In *Proceedings of the 10th National Conference on Artificial Intelligence: 717-722*
- [Rissanen 1985] Rissanen, J. (1985). Minimum description length principle. In S. Kotz, N.L. Johnson (Hrsg.), *Encyclopedia of Statistical Sciences*, Vol. 5: 523-532. John Wiley & Sons.
- [Schaffer 1990] Schaffer, C. (1990). A proven domain-independent scientific function-finding algorithm. In *Proceedings of the 8th National Conference on Artificial Intelligence: 828-833*
- [Steinhausen et al. 1977] Steinhausen, D., Langer, K. (1977). *Clusteranalyse*. Walter de Gruyter, Berlin, New York.
- [Wisotzki und Wysotzki, 1993] Wisotzki, C., Wysotzki, F. (1993). Lernfähige Klassifikation von Zeitreihen. In D. Fensel, G. Nakhaeizadeh (Hrsg.), *Proceedings des Workshops „Maschinelles Lernen: Theoretische Ansätze und Anwendungsaspekte“ auf der KI-Jahrestagung Berlin: 149-162*
- [Wrobel 1991] Wrobel, S. (1991). Towards a model of grounded concept formation. In *Proceedings of the 12th International Joint Conference on Artificial Intelligence: 712-719*. Morgan Kaufmann, San Mateo, CA.
- [Zembowicz und Zytkow 1992] Zembowicz, R., Zytkow, J.M. (1992). Discovery of Equations: Experimental Evaluation of Convergence. In *Proceedings of the 10th National Conference on Artificial Intelligence: 70-75*
- [Zytkow 1993] Zytkow, J.M. (1993) Introduction: Cognitive Autonomy in Machine Discovery. In *Machine Learning 12: 7-16*
- [Zytkow et al. 1990] Zytkow, J.M., Zhu, J., Hussam, A. (1990). Automated discovery in a chemistry laboratory. In *Proceedings of the 8th National Conference on Artificial Intelligence: 889-894*

Definitionen

Basiswahrnehmungsmerkmal	Prolog-Faktum mit sechs Argumenten, das die für die Navigation benötigten Informationen enthält
Intervall-Orientierung	Orientierung des Sensors während des Zeitintervalls eines Basiswahrnehmungsmerkmals
Intervall-Winkel	charakteristischer Wert des Zeitintervalls eines Basiswahrnehmungsmerkmals; repräsentiert alle Winkel, die jeweils für zwei aufeinanderfolgende Meßzeitpunkte im Intervall berechnet wurden
Kante	gerade Linien eines Raumes und eines Objektes im Raum - also Wände, Türrahmen, Seiten und Fronten von Schränken
Merkmalssymbol	Begriff, der die wesentlichen qualitativen Merkmale der in einem Zeitintervall zusammengefaßten Messungen beschreibt Beispiele: <i>increasing, no_measurement</i>
Parameter	regelt die Einzelheiten des Verfahrens zur Generierung der Basiswahrnehmungsmerkmale Beispiel: maximal erlaubte Differenz zwischen einem Winkel und dem Intervall-Winkel
Parametersatz	erlaubte Kombination von drei Verfahrensparametern und ein bis drei Parametern, die gemeinsam das Verfahren zur Generierung der Basiswahrnehmungsmerkmale festlegen
Trace	Weg, den ein mobiler Roboter in einem Raum nimmt
Verfahrensparameter	regelt, welche grundsätzliche Strategie das Verfahren zur Generierung der Basiswahrnehmungsmerkmale verfolgt Beispiel: Berechnung der Differenz zwischen einem Winkel und dem Intervall-Winkel als konstanter oder proportionaler Wert

Winkel	charakteristischer Wert für die Änderung der gemessenen Distanzen an zwei aufeinanderfolgenden Zeitpunkten
~, berechneter	Ein Winkel wird berechnet, wenn zwei Distanzen gemessen werden konnten, der Roboter im Zeitraum zwischen den beiden Meßzeitpunkten gefahren ist und sich nicht gedreht hat.
~, zugewiesener	In den übrigen Fällen wird ein Wert für den Winkel zugewiesen. Beispiel: 777 im Fall, daß sich der Roboter nicht bewegt hat