

Ein evidenztheoretischer Ansatz zur Planerkennung

Dissertation
zur Erlangung des Grades
Doktor der Ingenieurwissenschaften (Dr.-Ing.)
der Technischen Fakultät
der Universität des Saarlandes
von

Mathias Bauer

Saarbrücken
1996

Dekan der Technischen Fakultät: Professor Dr.-Ing. Alexander Koch

Tag des Kolloquiums: 26.11.1996

Prüfungsausschuß:

Vorsitzender: Professor Dr.-Ing. Jörg Siekmann

Gutachter: Professor Dr. Wolfgang Wahlster

Professor Dr. Alfred Kobsa

Erklärung

Hiermit erkläre ich, daß ich die vorliegende Arbeit ohne unzulässige Hilfe Dritter und ohne Benutzung anderer als der angegebenen Hilfsmittel angefertigt habe. Die aus anderen Quellen oder indirekt übernommenen Daten und Konzepte sind unter Angabe der Quelle gekennzeichnet.

Die Arbeit wurde bisher weder im In- noch im Ausland in gleicher oder ähnlicher Form in anderen Prüfungsverfahren vorgelegt.

Saarbrücken, den 17. März 1997

Danksagung

Hiermit bedanke ich mich bei meinem Doktorvater, Herrn Prof. Dr. Wolfgang Wahlster, für seine Bereitschaft, diese Arbeit zu betreuen und mir die notwendigen Freiräume zur Ausgestaltung meiner Forschungsarbeiten innerhalb der DFKI-Projekte PHI und RAP zu gewähren. Herrn Prof. Dr. Alfred Kobsa danke ich für seine spontane Bereitschaft, sich als Zweitgutachter zur Verfügung zu stellen.

Weiterhin bin ich meinen Kolleginnen und Kollegen Dr. Susanne Biundo, Dietmar Dengler, Harald Feibel und Gabriele Paul aus den Projekten PHI und RAP zu Dank verpflichtet für ihre Anregungen und stete Diskussionsbereitschaft.

Ein besonderer Dank geht auch an Markus Meyer für die Implementierung des Planerkenners sowie an Patrick Brandmeier für die Programmierung der Approximationsalgorithmen sowie seine aufopferungsvolle und geduldige Arbeit während der Durchführung der empirischen Untersuchungen.

Ein spezieller Dank gebührt meiner Frau Silvia, die mir jederzeit ein großer Rückhalt war, gerade während der letzten Monate, in denen sie viel zu oft auf mich verzichten mußte, und ohne deren Unterstützung diese Arbeit nicht möglich gewesen wäre.

Mathias Bauer

Saarbrücken, im Juli 1996

Kurzzusammenfassung

Planerkennung bedeutet, aus den beobachteten Aktionen eines Agenten auf dessen Pläne zu schließen. Das Wissen um diese Pläne – und damit die Intentionen und Ziele des Agenten – bildet beispielsweise die Grundlage für eine der aktuellen Situation angemessene Unterstützung durch ein intelligentes Hilfesystem. Sind nun mehrere Planhypothesen mit allen Beobachtungen kompatibel, so ist es notwendig, die *Qualität* der vorhandenen Alternativen beurteilen zu können. Die vorliegende Arbeit stellt einen Ansatz zur Bewertung von Planhypothesen auf der formalen Basis der Dempster-Shafer Theorie vor, der sowohl in der Lage ist, unsichere Evidenzen von mehreren Beobachtern zu verarbeiten, als auch agentenspezifische Information in Form eines quantitativen Benutzermodells zu berücksichtigen. Um diesem Ansatz eine formale semantische Basis zu verleihen, wird eine auf einer epistemischen Modallogik beruhende wahrscheinlichkeitstheoretische Charakterisierung der Dempster-Shafer Theorie für den Fall regelbasierter Systeme erweitert.

Abstract

Plan recognition means to infer an agent's plans by observing his actions. In an intelligent help system, for example, knowing about the agent's plan forms the basis for offering adequate support respecting his current situation and intentions. In case more than one plan hypothesis proved compatible with all the observations, the *quality* of these alternatives has to be assessed. This work presents an approach to the assessment of plan hypotheses on the formal basis of Dempster-Shafer Theory. It can both work with uncertain evidence from multiple observers and take into account agent specific information contained in a quantitative user model. This approach is given a formal semantics by extending a probabilistic characterization of Dempster-Shafer Theory based on an epistemic modal logic.

Zusammenfassung

Planerkennung, d.h. die Ableitung der Intentionen und Ziele eines Agenten aus der Beobachtung seines Verhaltens, ist eine zentrale Aufgabe in vielen verschiedenen Anwendungsgebieten der Künstlichen Intelligenz. Zu diesen zählen das Feld der Mensch-Maschine-Interaktion (HCI), das Verstehen natürlicher Sprache, Benutzer- und Studentenmodellierung, Multiagentensysteme und das Verstehen von Programmen.

Die vorliegende Arbeit ist im Bereich von Planerkennung und Benutzermodellierung anzusiedeln. Deren Ziel ist es, Annahmen über alle Aspekte eines Agenten, die für das Systemverhalten relevant sind, zu generieren, explizit zu modellieren und gegebenenfalls zu aktualisieren.

Unter der prinzipiellen Annahme eines *zielgerichteten Verhaltens* eines zu beobachtenden Agenten oder Systembenutzers bestehen zwei Arten der Interaktion zwischen einer Planerkennungs- und einer Benutzermodellierungskomponente. Einerseits erleichtert das Wissen um das *typische* Verhalten des Benutzers die Erkennung seines aktuellen Planes, wenn man diese Information als Fokussierungshilfe während des Erkennungsprozesses verwendet. Dieser Aspekt wird in der vorliegenden Arbeit von grundlegender Bedeutung sein. Andererseits liefert die Planerkennung Erkenntnisse über die Ziele und Präferenzen des Benutzers, die zur Aktualisierung des Benutzermodells verwendet werden können.

Ein Beispiel für solche agentenspezifische Information, die sich sowohl aus der beobachteten Interaktion aufgrund der erkannten Pläne ableiten läßt, als auch zur Einschränkung der Menge der *plausiblen* Planhypothesen verwendet werden kann, sind Daten bzgl. der Intentionen, Fähigkeiten und des Wissensstandes des Benutzers. Weiterhin fallen in diese Kategorie das Wissen über bestimmte "Attributwertpräferenzen", die Vorlieben eines Agenten hinsichtlich bestimmter Parameter seines Handelns repräsentieren und *quantitative Information* bzgl. des typischen Benutzerverhaltens.

Vorteilhaft im letzten Fall ist die Tatsache, daß diese Art der Information ein adäquates Mittel darstellt, die "Qualität" von Planhypothesen im Sinne ihrer Angemessenheit als Beschreibung des aktuellen Benutzerverhaltens zu repräsentieren. Somit kann in ambigen Situationen, in denen der aktuell verfolgte Plan nicht eindeutig aufgrund der beobachteten Aktionen allein identifiziert werden kann, eine Rangordnung unter den verbleibenden Alternativen berechnet und eines der grundlegenden Probleme vieler Planerkennungsansätze behoben werden. Viele Planerkenner unterhalten nämlich lediglich eine Menge aller Planhypothesen, die mit den bisherigen Beobachtungen kompatibel waren und alle als gleichermaßen plausible Erklärung für das Verhalten des Agenten betrachtet werden.

Verwendet man nun ein quantitatives Benutzermodell, das die "Wahrscheinlichkeit" verschiedener Pläne im Verhalten des betreffenden Benutzers widerspiegelt, so kann eine Fokussierung auf diejenigen Hypothesen vorgenommen werden, die dem typischen Verhalten *dieses* Benutzers am nächsten kommen. Somit kann der einfachen Tatsache Rechnung getragen werden, daß verschiedene Personen sich selbst bei gleicher Zielsetzung i.a. unterschiedlich verhalten, so daß derselbe Plan mehr oder weniger

gut zur Beschreibung dieses Verhaltens geeignet ist.

Die vorliegende Arbeit stellt einen Ansatz zur Integration des Schließens unter Unsicherheit in die Planerkennung vor. Es werden Methoden entwickelt, die die quantitative Bewertung der "Qualität" der verschiedenen Planhypothesen erlauben. Die Basis für eine solche Bewertung bildet eine Sammlung (statistischer) Daten, die das Verhalten eines oder mehrerer Agenten innerhalb einer gegebenen Domäne beschreiben. Ziel ist es, gerade diejenigen Hypothesen zu bevorzugen, d.h. mit einem höheren Wert zu markieren, die dem bisherigen Verhalten des zur Zeit beobachteten Agenten am besten entsprechen und daher – gemessen an der zur Verfügung stehenden Information – am "wahrscheinlichsten" sind. Die Berechnung einer dieses Kriterium erfüllenden Hypothesenbewertung kann unter anderem dazu verwendet werden, äußerst schlecht bewertete Hypothesen frühzeitig zu verwerfen oder zumindest ihre weitere Betrachtung vorerst zurückzustellen sowie die "beste(n)" Hypothese(n) auszuwählen, um etwa in Hilfesystemen aktive oder passive Hilfeleistung gezielt anbieten zu können.

Der vorgestellte Ansatz zielt darauf ab, Repräsentations- und Schlußfolgerungsmechanismen zur Verfügung zu stellen, die den grundlegenden Ansprüchen möglichst *aller* Planerkennungssysteme genügen, so daß deren Funktionalität durch die hier vorgestellten generischen Methoden erweitert werden kann.

Die formale Basis des Ansatzes bildet die Dempster-Shafer Theorie (DST), die als eine Verallgemeinerung der klassischen Wahrscheinlichkeitstheorie betrachtet werden kann. Neben *unsicherem* Wissen kann die DST auch das Fehlen von Information, also partielle oder sogar totale *Unwissenheit* explizit repräsentieren und bei Berechnungen berücksichtigen. Aus diesem Grund ist sie zur Modellierung des Verhaltens eines Agenten besonders geeignet, da die darüber zur Verfügung stehende Information inhärent unsicher und in den meisten Fällen unvollständig ist.

Um diesem Planerkennungsansatz eine formale semantische Basis zu verleihen, wird die von Ruspini entwickelte Theorie des evidenzbasierten Schließens um ein Konstrukt zur Repräsentation von *Regeln* erweitert, wodurch auf der Basis einer epistemischen Modallogik eine Einbettung in die klassische Wahrscheinlichkeitstheorie erreicht wird.

Darüberhinaus stellt diese Arbeit einen neuen Approximationsalgorithmus für die DST vor, der die exponentielle Komplexität der durchzuführenden Berechnungen umgeht, und vergleicht diesen empirisch mit bereits existierenden Verfahren. Die Auswertung der Ergebnisse erlaubt die Bewertung der Eignung dieser Algorithmen für unterschiedliche Anwendungsbereiche.

Die hier vorgelegte Arbeit entstand im Rahmen der am DFKI durchgeführten Forschungsprojekte PHI und RAP. Die Beschreibung der Integration der vorgestellten Konzepte in das jeweilige Gesamtsystem beschließt die Beschreibung des neuen Planerkennungsansatzes.

Summary

Plan recognition, i.e. inferring an agent's intentions and goals by observing his behavior, is a crucial task in many application areas of AI. These include the fields of human-computer interaction, natural language understanding, user and student modeling, multi agent systems, and program understanding.

The work presented here intersects with plan recognition and user modeling. The latter aims at the generation, explicit modeling, and update of all aspects of an agent that might be relevant to the system behavior.

Assuming a *goal-oriented behavior* of the agent or system user to be observed, two kinds of interaction exist between a plan recognition and a user modeling component. On the one hand, knowledge about a user's *typical* behavior can be used as a focusing aid during the recognition process, thus facilitating the identification of his current plan. This aspect will be of fundamental importance for the approach to be presented. On the other hand, plan recognition yields information about the user's goals and preferences that can be used to update the user model.

For example, information about a user's intentions, capabilities, and expertise can both be inferred from recognized plans and used to restrict the set of plausible plan hypotheses. Further examples include knowledge about a user's "attribute-value preferences"—representing preferences regarding the values of certain parameters of the user's acting—and *quantitative information* about his typical behavior.

If the latter is used as a measure of the "quality" of a plan hypothesis in the sense of its appropriateness as a description of the user's current behavior, it allows a ranking of all plan hypotheses to be computed whenever the user's actual plan cannot be uniquely identified on the basis of his observed behavior only. Thus one of the central problems of many approaches to plan recognition can be solved—the absence of a criterion to assess the plausibility of competing hypotheses in ambiguous situations.

A quantitative user model representing the "likelihood" of various plans within a certain user's behavior can thus be used to focus on hypotheses corresponding to *this person's* typical individual behavior. This reflects the fact that different persons tend to behave in different ways even when trying to accomplish the same goals and the quality of a hypothesis crucially depends on each person's peculiarities.

The approach to be presented integrates techniques of reasoning under uncertainty into plan recognition. Methods will be described that allow the quality of a plan hypothesis to be assessed quantitatively. A collection of (statistical) data representing a user's behavior in a given domain forms the basis for such an assessment. The aim is to prefer hypotheses that best match his former behavior as these are considered more likely than others, given the information available. Besides selecting the "best" hypothesis—e.g. to offer adequate support in a help system—the computation of a hypothesis assessment satisfying this criterion can be used to reject alternatives with extremely low values or at least defer their further consideration.

Representation means and inference mechanisms are provided that allow the com-

bination with most existing plan recognition systems, thus extending their respective functionalities.

The Dempster-Shafer Theory (DST) provides the formal basis for this new approach to plan recognition. It can be considered an extension of classical probability theory and is able to represent and deal with both *uncertain* and *incomplete* information. This fact makes DST especially suited to user modeling tasks where the available information is inherently uncertain and almost always only partially available.

Ruspini's theory of *evidential reasoning* is extended by a syntactic means to represent *rules*. This allows plan recognition to be embedded into classical probability theory by modeling the reasoning processes in an epistemic modal logic.

Additionally a new approximation algorithm for DST is presented that aims at avoiding the exponential complexity of the computations to be executed. In an empirical test it is compared with existing approximation methods, thus allowing their appropriateness to be assessed for various applications.

Most of this work was done as part of the DFKI projects PHI and RAP. A description of how the concepts presented are integrated in the respective overall systems concludes this account.

Inhalt

1	Einleitung	1
1.1	Planerkennung	3
1.2	Zielsetzung und Gliederung dieser Arbeit	8
2	Behandlung unsicheren und unvollständigen Wissens in der Dempster-Shafer Theorie	13
2.1	Grundlagen der Dempster-Shafer Theorie	13
2.2	Exkurs: Klassen von Wahrscheinlichkeiten	17
3	Ansätze zur Hypothesenbewertung in der Planerkennung	19
3.1	ATMS-basierte Systeme	19
3.1.1	Das System Wimp2	20
3.1.2	Das System NP	23
3.1.3	Das System IPS	24
3.2	Probabilistische Ansätze	26
3.2.1	Planerkennung mit einem probabilistischen Benutzermodell	26
3.2.2	Das System Wimp3	28
3.3	Systeme mit alternativen Unsicherheitsmodellen	33
3.3.1	Integration informationstheoretischer Maße	33
3.3.2	Modellierung von Default-Schlüssen mit Dempster-Shafer Theorie	37
3.4	Zusammenfassung der Ergebnisse	43
4	Eine modallogische Fundierung des evidenzbasierten Schließens	47
4.1	Die Grundlagen der Theorie des evidenzbasierten Schließens	48
4.1.1	Die epistemische Logik	50
4.1.2	Mögliche Welten und epistemische Zustände	51
4.1.3	Epistemische Zustände und Wahrscheinlichkeiten	54
4.1.4	Kombination von Wissen	59
4.1.5	Epistemologische Betrachtungen	64
4.2	Die Einführung von Konditionalen	64
4.2.1	Maßfreie Konditionale	66
4.2.2	Integration von Konditionalen in die epistemische Logik	69
4.2.3	Zusammenfassung	74

5	Regelbasierte Ansätze auf der Basis der Dempster-Shafer Theorie	77
5.1	Eine Erweiterung der Dempster-Shafer Theorie	78
5.2	Die Modifikation durch Guan und Bell	84
5.3	Eine wahrscheinlichkeitstheoretische Semantik für das System von Guan und Bell	89
5.3.1	Evidenz und Basiswahrscheinlichkeiten	90
5.3.2	Regeln und Konditionale	91
5.3.3	Berechnung der Hypothesenstärke	93
5.4	Analyse der vorgestellten Systeme	96
6	Planerkennung mit der Dempster-Shafer Theorie	99
6.1	Wissensarten und Wissensrepräsentation	99
6.1.1	Pläne und Planhierarchien	100
6.1.2	Agentenspezifisches Wissen	103
6.1.3	Einbettung in die Dempster-Shafer Theorie	106
6.2	Der Planerkennungsprozeß	130
6.2.1	Verarbeitung einer Beobachtung	130
6.2.2	Interpretation der Ergebnisse	149
6.3	Das quantitative Benutzermodell	154
6.3.1	Berechnung einer Basiswahrscheinlichkeit aus Intervallabschätzungen	154
6.3.2	Aktualisierung des Benutzermodells	166
6.4	Spezielle Aspekte der Planerkennung	174
6.4.1	Überlappende und verzahnte Pläne	175
6.4.2	Weitere Modellierungsaspekte	176
6.4.3	Die Vollständigkeitsannahme	177
6.5	Komplexitätsbetrachtungen	178
6.5.1	Berechnung der Hypothesenstärke	179
6.5.2	Approximative Berechnungen in der DST	179
6.6	Verfeinerung des Benutzermodells durch maschinelles Lernen	193
6.6.1	Motivation	193
6.6.2	Induktion von Entscheidungsbäumen	195
6.6.3	Anwendung auf die Planerkennung	199
6.6.4	Verwandte Arbeiten	204
7	Anwendung in PHI und RAP	207
7.1	Überblick über das Projekt PHI	207
7.2	Die Logik LLP	209
7.2.1	Syntax	210
7.2.2	Semantik	212
7.3	Planerkennung in PHI	215
7.3.1	Der abduktive Erkenner	215
7.3.2	Der Auswahlmodul	217

7.3.3	Ein konkretes Beispiel	222
7.4	Eingliederung in das Projekt RAP	227
8	Zusammenfassung und Ausblick	231
A	Exkurs: Algebraische Charakterisierung maßfreier Konditionale	235
B	Daten zum Beispiellauf des PHI-Systems	241

Abbildungsverzeichnis

3.1	Aussagenbaum im ATMS nach Eingabe von <code>(inst rope-27 rope)</code> . . .	22
3.2	Die Architektur von IPS.	25
3.3	Ein assoziatives Netz in der Wissensbasis von Wimp3.	29
3.4	Konstruktion eines PRN durch Anwendung der Regel “Slot-filler.” . . .	31
3.5	Expansion eines PRN durch Anwendung der Regel “Up-existential.” . .	31
3.6	Beispiel eines Kontextmodells.	38
5.1	Bijektionen zwischen Evidenzenräumen und epistemischen Algebren. . .	93
5.2	Der durch eine Evidenz ausgelöste Informationsfluß.	95
6.1	Die Planhierarchie \mathcal{H}	102
6.2	Eine modifizierte Planhierarchie.	111
6.3	Partitionierung durch $\mathcal{C}(\Theta)$	114
6.4	Effekt einer Δ -Partitionierung $\mathcal{C}(\Theta)$	118
6.5	Zwei prototypische Beobachtungsregeln R_1 und R_2	120
6.6	Eine Beobachtungsregel mit allen auftretenden Modifikationen.	127
6.7	Der durch eine Evidenz ausgelöste Informationsfluß.	129
6.8	Der Erklärungsgraph nach der Beobachtung MakeMarinara.	133
6.9	Der Erklärungsgraph der disjunktiven Beobachtung MakeSauceCarbonara \vee MakeMarinara.	137
6.10	Die Erklärungsgraphen für die Beobachtungen MakeSauceCarbonara und MakeSauce.	140
6.11	Zwei Beobachtungsregeln in einem Szenario mit indirekter Beobachtung.	147
6.12	Dieselben Regeln nach der Verkettung.	148
6.13	Analysegraph für <i>eine</i> Beobachtung.	151
6.14	Modifizierter Analysegraph für <i>eine</i> Beobachtung.	152
6.15	Die Prozedur für Phase 1.	158
6.16	Zwei der induzierten Basiswahrscheinlichkeiten.	163
6.17	Die Beobachtungsregeln R_1 und R_2	171
6.18	Der k - l - x -Approximationsalgorithmus.	182
6.19	Der Approximationsalgorithmus D1.	185
6.20	Beispiel für die Arbeitsweise von D1.	186
6.21	Ergebnisse bzgl. Error1.	190
6.22	Ergebnisse bzgl. Error2.	191

6.23	Ergebnisse bzgl. Error3.	192
6.24	Beispiel einer Planhierarchie für die email-Domäne.	193
6.25	Der von ID3 erzeugte Entscheidungsbaum.	198
6.26	Der Entscheidungsbaum $T(\text{read_message})$	201
7.1	Die Gesamtarchitektur von PHI.	208
7.2	Die Architektur des Planerkennters in PHI.	215
7.3	Die Oberfläche des PHI-Systems während der Klassifikationsphase.	222
7.4	Die Planspezifikation p1 in interner Darstellung.	223
7.5	Der aus Spezifikation p1 generierte Plan.	224
7.6	Das PHI-System nach der Klassifikationsphase.	225
7.7	Das PHI-System nach Verwerfen der Hypothese p4.	226
7.8	Die Architektur des RAP-Systems.	228
7.9	Ein Modulnetz mit Planerkennung und Erklärungskomponente.	229

Tabellenverzeichnis

3.1	Vergleich der in diesem Kapitel vorgestellten Ansätze.	45
4.1	Materielle Implikation und Konditionierung.	68
4.2	Ableitbarkeitsverhalten von \rightarrow und $ $	68
5.1	Wichtige Eigenschaften der betrachteten Systeme.	98
6.1	Überblick über die Regelklassen.	123
6.2	Die durch m_1 induzierten Vertrauensintervalle für die Pläne der Abstraktionshierarchie.	135
6.3	Die durch m'_1 induzierten Vertrauensintervalle für die Pläne aus \mathcal{H} . . .	138
6.4	Die durch m''_1 induzierten Vertrauensintervalle für die Pläne aus \mathcal{H} . . .	141
6.5	Die durch m'''_1 induzierten Vertrauensintervalle für die Pläne aus \mathcal{H} . . .	144
6.6	Die durch m''''_1 induzierten Vertrauensintervalle für die Pläne aus \mathcal{H} . . .	146
6.7	Quantitativer Vergleich der Approximationsalgorithmen.	189
6.8	Trainingsbeispiele für ID3.	197

Kapitel 1

Einleitung

Planerkennung, d.h. die Ableitung der Intentionen und Ziele eines Agenten aus der Beobachtung seines Verhaltens, ist eine zentrale Aufgabe in vielen verschiedenen Anwendungsgebieten der Künstlichen Intelligenz. Zu diesen zählen das Feld der Mensch-Maschine-Interaktion (HCI), das Verstehen natürlicher Sprache, Benutzer- und Studentenmodellierung, Multiagentensysteme und das Verstehen von Programmen. Entsprechend vielfältig sind die Berührungspunkte mit unterschiedlichen Disziplinen der KI, die einerseits von den existierenden Planerkennungstechniken profitieren, andererseits aber auch zu deren Weiterentwicklung beitragen. Diese umfassen die meisten Teilgebiete der KI wie Planen, Wissensrepräsentation, Verarbeitung natürlicher Sprache und Benutzermodellierung, aber auch temporales Schließen, Deduktion, Abduktion und Schließen unter Unsicherheit (siehe dazu auch [Bauer, 1995b]).

Von all diesen Gebieten besteht eine besonders enge Verbindung zur Benutzermodellierung, deren Ziel es ist, Annahmen über alle Aspekte eines Agenten, die für das Systemverhalten relevant sind, zu generieren, explizit zu modellieren und gegebenenfalls zu aktualisieren (siehe dazu auch [Wahlster und Kobsa, 1986]). Nach [Kass und Finin, 1991] benötigt ein System ein Benutzermodell zumindest in folgenden Fällen.

- Wenn das System versucht, *adaptiv* zu sein, d.h. den Benutzer unter Berücksichtigung seiner Präferenzen und aktuellen Ziele zu unterstützen, indem beispielsweise die Benutzerschnittstelle umorganisiert (siehe z.B. [Goodman und Litman, 1992]) oder die vom System generierten Antworten an die aktuellen Bedürfnisse angepaßt werden (wie etwa in [Paris, 1988]).
- Wenn das System *Verantwortung* für den Erfolg der aktuellen Interaktion übernimmt oder diese mit dem Benutzer teilt. Im Gegensatz dazu sind interaktive Systeme zu sehen, bei denen der Benutzer alleine für das vom System produzierte Ergebnis verantwortlich ist. In letztere Klasse fallen die meisten “herkömmlichen” Softwareanwendungen wie Textverarbeitung.
- Wenn die Klasse der potentiellen Benutzer oder seiner Verwendungsmöglichkeiten sehr vielfältig ist. Hier spielt der Aspekt der gezielten *Hilfe* durch das

System unter Berücksichtigung des Wissens und der Ziele einzelner Benutzer (oder Klassen von Benutzern) eine entscheidende Rolle.

Dies läßt sich zusammenfassen durch

“In general, an interactive system may need to reason about a user’s beliefs, goals and plans, preferences and attitudes, or capabilities to understand his or her actions and control the system’s own behavior.” [Kass und Finin, 1991]

Um nun bei diesen verschiedenen Aufgabenstellungen nicht auf die Verwendung eines *statischen* Benutzermodells angewiesen zu sein, das eine über einen längeren Zeitraum erworbene Beschreibung des Wissens des Benutzers, seiner Präferenzen und Ziele beinhaltet, kann die Planerkennung verwendet werden, die Verbindung zur *aktuellen* Situation des Benutzers herzustellen. Durch die Ableitung seiner momentanen Ziele und Pläne aus der Beobachtung seiner Aktionen – beispielsweise der Interaktion mit einer Softwareanwendung – können die oben erläuterten Dienstleistungen des Systems wie Adaption *kontextsensitiv*, d.h. unter Berücksichtigung der *momentanen* Anforderungen, erbracht werden.

Unter der prinzipiellen Annahme eines *zielgerichteten Verhaltens* eines zu beobachtenden Agenten oder Systembenutzers bestehen zwei Arten der Interaktion zwischen einer Planerkennungs- und einer Benutzermodellierungskomponente. Einerseits erleichtert das Wissen um das *typische* Verhalten des Benutzers die Erkennung seines aktuellen Planes, wenn man diese Information als Fokussierungshilfe während des Erkennungsprozesses verwendet. Dieser Aspekt wird in der vorliegenden Arbeit von grundlegender Bedeutung sein. Andererseits liefert die Planerkennung Erkenntnisse über die Ziele und Präferenzen des Benutzers, die zur Aktualisierung des Benutzermodells verwendet werden können.

Ein Beispiel für solche agentenspezifische Information, die sich sowohl aus der beobachteten Interaktion aufgrund der erkannten Pläne ableiten läßt, als auch zur Einschränkung der Menge der *plausiblen* Planhypothesen verwendet werden kann, sind Daten bzgl. der Intentionen, Fähigkeiten und des Wissensstandes des Benutzers (wie beispielsweise in [Ardissono und Sestero, 1996; Ardissono, 1996]). Weiterhin fallen in diese Kategorie das Wissen über bestimmte “Attributwertpräferenzen”, die Vorlieben eines Agenten hinsichtlich bestimmter Parameter seines Handelns repräsentieren (siehe dazu [Elzer *et al.*, 1994]) und *quantitative Information* bzgl. des typischen Benutzerverhaltens (siehe etwa [Bauer, 1995a]).

Vorteilhaft im letzten Fall ist die Tatsache, daß diese Art der Information ein adäquates Mittel darstellt, die “Qualität” von Planhypothesen im Sinne ihrer Angemessenheit als Beschreibung des aktuellen Benutzerverhaltens zu repräsentieren. Somit kann in ambigen Situationen, in denen der aktuell verfolgte Plan nicht eindeutig aufgrund der beobachteten Aktionen allein identifiziert werden kann, eine Rangordnung unter den verbleibenden Alternativen berechnet und eines der grundlegenden

Probleme vieler Planerkennungsansätze behoben werden. Viele Planerkenner unterhalten nämlich lediglich eine Menge aller Planhypothesen, die mit den bisherigen Beobachtungen kompatibel waren und alle als gleichermaßen plausible Erklärung für das Verhalten des Agenten betrachtet werden.

Verwendet man nun ein quantitatives Benutzermodell, das die “Wahrscheinlichkeit” verschiedener Pläne im Verhalten des betreffenden Benutzers widerspiegelt, so kann eine Fokussierung auf diejenigen Hypothesen vorgenommen werden, die dem typischen Verhalten *dieses* Benutzers am nächsten kommen. Somit kann der einfachen Tatsache Rechnung getragen werden, daß verschiedene Personen sich selbst bei gleicher Zielsetzung i.a. unterschiedlich verhalten, so daß derselbe Plan mehr oder weniger gut zur Beschreibung dieses Verhaltens geeignet ist.

Die vorliegende Arbeit stellt einen Ansatz zur Integration des Schließens unter Unsicherheit in die Planerkennung vor. Es werden Methoden entwickelt, die die quantitative Bewertung der “Qualität” der verschiedenen Planhypothesen erlauben. Die Basis für eine solche Bewertung bildet eine Sammlung (statistischer) Daten, die das Verhalten eines oder mehrerer Agenten innerhalb einer gegebenen Domäne beschreiben. Ziel ist es, gerade diejenigen Hypothesen zu bevorzugen, d.h. mit einem höheren Wert zu markieren, die dem bisherigen Verhalten des zur Zeit beobachteten Agenten am besten entsprechen und daher – gemessen an der zur Verfügung stehenden Information – am “wahrscheinlichsten” sind. Die Berechnung einer dieses Kriterium erfüllenden Hypothesenbewertung kann unter anderem dazu verwendet werden, äußerst schlecht bewertete Hypothesen frühzeitig zu verwerfen oder zumindest ihre weitere Betrachtung vorerst zurückzustellen sowie die “beste(n)” Hypothese(n) auszuwählen, um etwa in Hilfesystemen aktive oder passive Hilfeleistung gezielt anbieten zu können.

Der vorgestellte Ansatz zielt darauf ab, Repräsentations- und Schlußfolgerungsmechanismen zur Verfügung zu stellen, die den grundlegenden Ansprüchen möglichst *aller* Planerkennungssysteme genügen, so daß deren Funktionalität durch die hier vorgestellten generischen Methoden erweitert werden kann.

Der Rest dieses Kapitels stellt zunächst das Forschungsgebiet der Planerkennung mit seinen grundlegenden Arbeiten und neuesten Trends vor. Die Gliederung der Arbeit und kurze Übersichten zu den einzelnen Abschnitten beenden dieses Kapitel.

1.1 Planerkennung

Planerkennung bedeutet, aus den beobachteten Aktionen oder Äußerungen eines Agenten auf dessen Pläne, Intentionen und Ziele zu schließen. Sie spielt in vielen verschiedenen Gebieten der KI eine zentrale Rolle. So bildet Planerkennung im Umfeld der Mensch-Maschine-Kommunikation und Helpware die Grundlage für qualifizierte Hilfe für die Anwender komplexer Softwaresysteme (z.B. [Hecking *et al.*, 1988; Goodman und Litman, 1992; Mayfield, 1992; Thies und Berger, 1992; Bauer und Paul, 1993; Bauer *et al.*, 1993]). Im Bereich des Verstehens natürlicher Sprache unterstützt sie die

Interpretation und Disambiguierung von Äußerungen, beispielsweise in Beratungssystemen (z.B. [Myers, 1989; Carberry, 1990a; Carberry, 1990b; Carberry, 1990c; Raskutti und Zukerman, 1991a; Raskutti und Zukerman, 1991b]). Weitere Anwendungen umfassen das Geschichtenverstehen (z.B. [Charniak und Goldman, 1989; Charniak und Goldman, 1993]), Generierung und Aktualisierung von Benutzer- und Studentenmodellen (z.B. [Wu, 1991; Ardissono *et al.*, 1994]), Programmerkennung (z.B. [Wills, 1990]) sowie Multiagentenszenarien, in denen Planerkennung etwa zur Aufdeckung von Zielkonflikten und Möglichkeiten zur Zusammenarbeit eingesetzt werden kann (z.B. [Huber und Durfee, 1992; Huber und Durfee, 1993]).

Der Rest dieses Abschnitts beschreibt kurz die grundlegenden Arbeiten, die die Forschung auf dem Gebiet der Planerkennung wesentlich beeinflusst haben, sowie die aktuellen Trends. [Schmidt *et al.*, 1978] beleuchtet die *psychologische* Seite, bei der es um die Untersuchung des Prozesses geht, mit dem ein Beobachter einer linear geordneten Folge von Ereignissen oder Aktionen eine intentionale Interpretation zuordnet. Zentraler Punkt ist die Definition des “Planerkennungsproblems” als

“[...] to take as input a sequence of actions performed by an actor and to infer the goal pursued by the actor and also to organize the action sequence in terms of a plan structure.”

Mittels psychologischer Studien wird nachgewiesen, daß menschliche Beobachter prinzipiell in der Lage sind, Planerkennung in diesem Sinne zu betreiben, und daß diese im alltäglichen Leben auch tatsächlich angewandt wird. Das vorgestellte System BELIEVER versucht auf der Basis

- eines *Personenmodells*, das Wissen, Glauben, Absichten usw. des Agenten enthält,
- eines *Weltmodells*, das die gültigen Fakten über die Welt beschreibt, sowie
- eines *Planmodells*, in dem generisches Planungswissen gespeichert ist,

die aktuell beobachtete Aktionssequenz mit Hilfe eines Plangenerierers auf eine sogenannte *Erwartungsstruktur* abzubilden, die die intentionale Struktur des beobachteten Verhaltens widerspiegelt.

Die wichtigsten Arbeiten, die die *formalen* Grundlagen der Planerkennung in einem logischen Rahmen beschreiben und insbesondere durch die exakte Definition von Planhierarchien, Abstraktions- und Dekompositionsbeziehungen zwischen Plänen die Mehrzahl der nachfolgenden Ansätze beeinflussten, stammen von Henry Kautz und James Allen [Kautz und Allen, 1986; Kautz, 1987; Kautz, 1991]. Basis der Planerkennung ist dabei eine prädikatenlogische Theorie, die eine solche Planhierarchie mit allen wesentlichen Aspekten beschreibt, und die durch mehrfache Anwendung von *Circumscription* [McCarthy, 1980] abgeschlossen wird. Dies bedeutet, daß das beschriebene Wissen unter verschiedenen Gesichtspunkten als *vollständig* betrachtet wird, wodurch es möglich ist, beobachtete Aktionen durch Deduktionen mit den Planhierarchie-Axiomen in (abstrakte) Pläne einzuordnen (d.h. diese als Theoreme abzuleiten). Eine

konkrete Implementierung eines Planerkennungssystems auf der Basis dieser Theorie wird in den Abschnitten 6.2.1.2 bis 6.2.1.4 im Zusammenhang mit der Kopplung mit den in dieser Arbeit vorgestellten Methoden beschrieben. Verwandte Arbeiten, die dieser “Schule” der Planerkennung zuzurechnen sind, sind beispielsweise [Wobcke, 1988; Hecking, 1993].

Viele Planerkennungsansätze sind dadurch charakterisiert, daß die zur Verfügung stehenden Planbibliotheken eine Art Grammatik für Pläne definieren. Beobachtete Aktionen gemäß dieser Grammatik zu klassifizieren, kann dann als eine *Parsing-Aufgabe* betrachtet werden. Dies trifft auch auf den Kautz’schen Ansatz zu, wie in [Vilain, 1990] erläutert wird. Zu dieser Klasse von Planerkennern sind auch solche zu zählen, bei denen die Plandekompositionen die Form endlicher Automaten annehmen. Hier wird ein Eingabestring von Aktionen als Instanz eines bestimmten Planes erkannt, wenn durch diese Eingabe ein Endzustand innerhalb des Automaten erreicht wird, wenn die Beobachtungen also zu der durch den Automaten definierten “Plansprache” gehören. Zu diesen Ansätzen sind u.a. [Hecking *et al.*, 1988; Bauer *et al.*, 1988; Retz-Schmidt, 1988; Retz-Schmidt, 1991], im weitesten Sinne aber auch neuere Arbeiten wie [Devanbu und Litman, 1991; Weida und Litman, 1992] (s.u.) zu zählen. Eine Übersicht über die Grundlagen der Planerkennung als Parsing findet sich in [Vilain, 1990].

Die neuesten Entwicklungen in der Planerkennung lassen sich grob in folgende Kategorien unterteilen, wobei auch Mischformen auftreten:

1. Abduktive Ansätze
2. Planerkennung als Constraint erfüllungsproblem
3. Planerkennung mit terminologischen Logiken
4. Planerkennung als maschinelles Lernen
5. Integration numerischer Verfahren

zu 1.: Abduktive Verfahren versuchen, Beobachtungen zu erklären, indem bestimmte *abduzible* Hypothesen gesucht werden, deren Auftreten das beobachtete Phänomen verursachen.¹ Die grundlegende Schlußfolgerungsregel der Abduktion

$$\frac{\beta, \alpha \rightarrow \beta}{\alpha}$$

erlaubt, vom Auftreten eines “Symptoms” β auf eine mögliche Ursache oder Erklärung α zu schließen. Bezogen auf die Planerkennung bedeutet dies, ausgehend von einer beobachteten Aktion (hier β) eines Agenten auf solche Pläne zu schließen, die diese Aktionen als Bestandteil ihrer funktionalen Dekomposition beinhalten (hier repräsentiert durch die Implikationsbeziehung zwischen dem “Plan” α und β). Insofern liegt es

¹Ein Überblick über Abduktion im allgemeinen findet sich in [Paul, 1993].

nahe, Planerkennung als ein inhärent abduktives Problem zu betrachten (siehe dazu auch [Shanahan, 1989]). Dies steht im Gegensatz zur rein *deduktiven* Sichtweise des Ansatzes von Kautz.

Zu den abduktiven Planerkennungsansätzen zählen die Arbeiten [Appelt und Pollock, 1990], bei der die *Kosten* einzelner abduktiver Schritte berücksichtigt werden, um die wahrscheinlichste Hypothese auswählen zu können, sowie der im Rahmen des Projektes PHI am DFKI entwickelte Ansatz der *temporalen Abduktion*, der in der Planungslogik LLP repräsentierte Pläne inkrementell erkennen kann (siehe dazu auch Abschnitt 7.3).

In [Wærn, 1994] wird ein neuer Ansatz zur abduktiven Planerkennung vorgestellt (“PID”), der es ermöglicht, verschiedene Optimalitätskriterien bzgl. möglicher Erklärungen zu berücksichtigen. Prinzipiell wird hier nicht vorausgesetzt, daß alle Beobachtungen durch einen Plan erklärt werden müssen. Die Frage, *was* erklärt werden soll, hängt vom jeweiligen Kontext und dem vorgesehenen Verwendungszweck der Erklärung ab.

zu 2.: Eine neue Sichtweise auf die Planerkennung findet sich in [Hong, 1993; Hong, 1994]. Der Anspruch dieser Arbeiten besteht darin, durch eine detailliertere Beschreibung der Relationen zwischen Aktionen und Plänen zu besseren Erkennungsergebnissen zu gelangen als dies bei Kautz der Fall ist. Die sich durch diese größere Menge an Constraints ergebenden stärkeren Einschränkungen hinsichtlich der möglichen zukünftigen Aktionen des Benutzers sollen schneller zur eindeutigen Identifizierung eines Planes führen.

Grundlage für die Erkennung ist eine sogenannte “Aktionshierarchie”, die neben der Dekomposition von Plänen in Aktionen auch Informationen bzgl. “Generierungs-” und “Enablement”-Relationen beinhaltet. Dabei *generiert* beispielsweise das Drehen des Autoschlüssels das Starten des Wagens. Auf der Planebene entspricht eine solche Relation im wesentlichen der üblichen Abstraktionsbeziehung. “Enablement” hingegen bedeutet, daß das Ausführen einer Aktion *A* einen Teil der notwendigen Voraussetzungen zur Ausführung einer Aktion *B* erzeugt. Vor Beginn der Planerkennung wird eine solche Hierarchie ähnlich wie in [Kautz und Allen, 1986] mittels Circumscription “abgeschlossen”, so daß deduktive Schlußfolgerungen “in beiden Richtungen” ermöglicht werden.

Werden nun konkrete Aktionen beobachtet, so wird in einem ersten Schritt durch Propagierung der Generierungsconstraints eine initiale “Planhierarchie” aufgebaut, die den jeweils aktuellen Zustand der Hypothesenmenge widerspiegelt. Durch Anwendung von Dekompositionssaxiomen werden davon ausgehend Pläne hypothetisiert, die mögliche Kandidaten für die Erklärung der beobachteten Aktionen sind. Dabei können u.U. weitere Aktionen, die nicht über ein Generierungsconstraint mit diesen Plänen verbunden werden konnten, in diese eingegliedert werden. Schließlich wird versucht, die verbleibenden Aktionen durch Ausnutzung von “Enablement”-Information in diese Planhierarchie einzugliedern, indem diese als Voraussetzung für eine erwartete Aktion innerhalb einer aktuellen Planhypothese betrachtet werden. Den Abschluß

bildet die Überprüfung aller temporalen Constraints zwischen den Elementen der so aufgebauten Planhierarchie sowie der sogenannte “Plan Checker”, der überprüft, ob ein Plan bereits vollständig durch die beobachteten Aktionen und die daraus abgeleitete Information beschrieben wird.

Es wird nicht substantiiert dargelegt, inwiefern das ursprüngliche Ziel der exakteren Identifizierung einzelner Pläne anstelle minimaler Planmengen wie bei Kautz erreicht wurde.

zu 3.: Während die meisten der bisher erwähnten Ansätze Pläne durch eine Menge prädikatenlogischer Formeln repräsentieren, die sowohl Dekompositions-, als auch Abstraktionsbeziehungen explizit darstellen, basieren einige neuere Arbeiten auf terminologischen Wissensrepräsentationssystemen (TKRs). Beispiele hierfür sind [Devanbu und Litman, 1991; Weida und Litman, 1992; Weida und Litman, 1994; Weida, 1995].

Das in [Devanbu und Litman, 1991] vorgestellte CLASP System erweitert konventionelle TKRs derart, daß temporale und strukturelle Beziehungen zwischen Aktionen repräsentiert und diese somit zu Plänen zusammengefaßt werden können. Subsumption und Klassifikation von Plänen auf der Basis “konventioneller” Termsubsumption erlauben die automatische Erstellung von Planhierarchien.

In [Weida und Litman, 1992] werden Pläne als sogenannte “Constraint Networks” dargestellt, die ebenfalls temporale und strukturelle Beziehungen zwischen Aktionen darstellen. Das System T-REX organisiert diese in Form “terminologischer Planbibliotheken.” Planerkennung bedeutet in diesem Kontext, die aktuellen Beobachtungen ebenfalls in ein solches Constraint Network zu übersetzen und die so gewonnene Instanz bzgl. der gegebenen Planbibliothek zu “realisieren”, d.h. diejenigen Pläne zu finden, zu denen die Beobachtungen “passen.” Als Seiteneffekt ergibt sich dabei eine Dreiteilung der Planbibliothek in *unmögliche*, *mögliche* und *notwendige* Konzepte, je nachdem, wie hoch der Grad der Übereinstimmung der Beobachtungen mit den entsprechenden Plänen ist.

Eine zusätzliche Erweiterung wird in [Weida und Litman, 1994] beschrieben. Die sogenannten *QME Networks* (“qualitative, metric and equality”) sind in der Lage, außer qualitativen zeitlichen Relationen auch metrische Information bzgl. Anfangs- und Endzeitpunkt von Zeitintervallen sowie Gleichheitsconstraints zwischen Rollen verschiedener Konzepte zu repräsentieren und bei Inferenzen zu berücksichtigen.

Ein ähnlicher Ansatz zur Repräsentation von Plänen in einer terminologischen Logik wird auch im System RAT (“Representation of Actions in Terminological Logics”) [Wahlster *et al.*, 1993] und dessen Erweiterung zur Behandlung temporaler Constraints [André und Rist, 1996] verfolgt. Der Schwerpunkt liegt hierbei jedoch nicht auf der Planerkennung, sondern der Generierung von Domänen- und Präsentationsplänen für ein Multimedia-System.

zu 4.: In [1995a; 1995b] unternehmen Lesh und Etzioni den Versuch, Planerkennung als eine spezielle Instanz maschinellen Lernens zu interpretieren, wobei das Schließen von einzelnen Beobachtungen zu komplexen Plänen oder Zielen mit der Generalisie-

rung von Beispielen zu abstrakten Konzeptbeschreibungen verglichen wird. Entsprechend dem Vorgehen beim induktiven Lernen kann ein Planerkenner dann durch Angabe seines “Bias”, also der zulässigen Ziel- und Planbeschreibungen, charakterisiert und mit anderen verglichen werden. Die hierarchische Anordnung aller Hypothesen in Form eines sogenannten “Version Space” erlaubt eine äußerst effiziente Verarbeitung von Beobachtungen, sofern gewisse Bedingungen hinsichtlich des Auftretens redundanter Aktionen erfüllt sind.

zu 5.: Eines der grundlegenden Probleme all dieser Planerkennungsansätze ist die Tatsache, daß die “Vorabwahrscheinlichkeit” bestimmter Pläne nicht berücksichtigt wird, so daß zu keinem Zeitpunkt eine Reihenfolge aller Planhypothesen berechnet werden kann. Die Integration numerischer Verfahren zur quantitativen Bewertung dieser Hypothesen kann dazu verwendet werden, dieses Problem zu bewältigen. Entsprechende Ansätze werden in Kapitel 3 ausführlich beschrieben.

1.2 Zielsetzung und Gliederung dieser Arbeit

Dieser Abschnitt faßt die grundlegende Zielsetzung der vorliegenden Arbeit zusammen und erläutert den Aufbau der nachfolgenden Kapitel. Die dabei diskutierten Ziele werden in Kapitel 3 als Bewertungskriterien für die dort analysierten Planerkennungsansätze dienen.

Viele Anwendungen von Planerkennungssystemen (im folgenden kurz PE-Systeme) bewegen sich im Rahmen von Hilfe- oder Tutorssystemen für die Benutzer komplexer Softwaresysteme. Solche Domänen sind dadurch gekennzeichnet, daß sowohl alle ausgeführten Aktionen – nämlich die vom Benutzer eingegebenen Kommandos – als auch der aktuelle Zustand der Welt – hier die aktuellen Werte wichtiger Systemparameter – eindeutig identifiziert werden können. Wendet man sich jedoch anderen Anwendungsfeldern zu, die beispielsweise gesprochene Sprache oder die Ausgabe unterschiedlicher Arten von Sensoren verarbeiten (siehe etwa [Barès *et al.*, 1994]), so können sowohl die Beobachtungen als auch die Aussagen bzgl. des Weltzustandes mit Unsicherheit behaftet sein. Da all diese Information von grundlegender Bedeutung für ein PE-System sind, ist die Fähigkeit zur Verarbeitung *unsicherer Evidenzen* Voraussetzung für dessen Verwendbarkeit in Realwelt-Szenarien.

In vielen Anwendungsgebieten ist es wünschenswert, daß ein PE-System jederzeit in der Lage ist, bzgl. eines Qualitätskriteriums eine Reihenfolge unter seinen aktuellen Planhypothesen zu berechnen, um gegebenenfalls die beste dieser Hypothesen auswählen zu können. Dies ist z.B. in Hilfesystemen der Fall, wenn für den Benutzer eine auf seine aktuelle Situation maßgeschneiderte Hilfeleistung erbracht werden soll. Eine weitere Verwendung einer solchen Hypothesenbewertung ist das vorzeitige Verwerfen extrem schlecht bewerteter Alternativen. Grundlage für das Aufstellen einer Rangordnung ist eine *quantitative Bewertung* aller Hypothesen.

Wie bereits zu Beginn dieses Kapitels erwähnt, ist hierbei die Verwendung *agen-*

tenspezifischer Information vorteilhaft, da diese eine auf das typische Verhalten einer Person fokussierte Planerkennung ermöglicht. Solches Wissen in Form eines Benutzermodells ist *inhärent unsicher* und meist *unvollständig*. Dieser Tatsache muß ein robustes PE-System Rechnung tragen.

Ebenso wie für Expertensysteme, ist es auch für PE-Systeme erforderlich, ihre Entscheidungen und die ihnen zugrundeliegenden Berechnungen gegenüber dem Benutzer zu *erklären und rechtfertigen*. Dies erhöht einerseits die Akzeptanz getroffener Entscheidungen und ermöglicht andererseits eine Überprüfung der vom System verwendeten Daten auf Konsistenz und Plausibilität.

Voraussetzung für eine solche Erklärung ist die eindeutige Interpretierbarkeit der vom System berechneten Ergebnisse. Diese wird durch Angabe einer *formalen Semantik* geschaffen.

Die Zielsetzung der vorliegenden Arbeit ist somit folgende. Es soll ein Planerkennungsansatz entwickelt werden, der

- *unsichere Beobachtungen* verarbeiten kann, die von *einem oder mehreren Beobachtern* geliefert werden,
- die "Qualität" konkurrierender Planhypothesen *quantitativ* erfaßt, so daß jederzeit eine Entscheidung für eine optimale Hypothese getroffen werden kann,
- *agentspezifische Information* in Form eines Benutzermodells verarbeitet und aktualisiert,
- *unsichere und unvollständige Information* adäquat behandelt,
- die Auswahl von Hypothesen *rechtfertigen und erklären* kann und
- eine *formale semantische Basis* besitzt.

Der Rest dieser Arbeit ist wie folgt aufgebaut: Kapitel 2 führt wesentliche Grundbegriffe aus der Dempster-Shafer Theorie ein, die für das Verständnis der folgenden Kapitel notwendig sind, und erläutert deren Zusammenhang mit bestimmten wahr-scheinlichkeitstheoretischen Konzepten.

Kapitel 3 stellt verschiedene Planerkennungssysteme unter dem Gesichtspunkt der Behandlung ambiger Situationen vor, die durch das Vorhandensein mehrerer plausibler Planhypothesen gekennzeichnet sind. Neben ATMS-basierten Systemen werden wahrscheinlichkeitstheoretische Ansätze behandelt, die entweder auf einem statischen probabilistischen Benutzermodell aufbauen, das die Wahrscheinlichkeit der einzelnen Pläne für das Verhalten eines bestimmten Agenten quantifiziert, oder aber auf dynamisch generierten Bayesschen Netzen, die die gegenseitigen Abhängigkeiten verschiedener Parameter in der Beschreibung einer Situation kodieren. Den Abschluß bildet die Diskussion von Ansätzen mit alternativen Unsicherheitsmodellen, die entweder informationstheoretische Maße in die Berechnung der Bewertung einer Planhypothese

einfließen lassen oder aber die Dempster-Shafer Theorie zur Modellierung von Default-Schlüssen in der Planerkennung verwenden.

Ziel dieser Arbeit ist die Entwicklung eines regelbasierten, evidenztheoretisch fundierten Ansatzes zur Planerkennung. Dieser Ansatz kombiniert den Formalismus der Dempster-Shafer Theorie mit Techniken aus dem Bereich der Expertensysteme. Die beiden nachfolgend beschriebenen Kapitel dienen dazu, auf jedem dieser beiden Forschungsgebiete die jeweils erforderlichen Grundlagen zu schaffen.

Kapitel 4 führt in die Theorie des evidenzbasierten Schließens ein, mit deren Hilfe die Dempster-Shafer Theorie als Erweiterung der klassischen Wahrscheinlichkeitstheorie charakterisiert werden kann und somit eine probabilistische Semantik erhält. Die Erweiterung der dieser Theorie zugrundeliegenden epistemischen Logik um das Sprachkonstrukt des Konditionals erlaubt einerseits die syntaktische Behandlung bedingter Ereignisse innerhalb dieser Logik, verletzt aber andererseits grundlegende algebraische Eigenschaften. Deshalb werden Konditionale nur in stark eingeschränkter Form zur Repräsentation von "Expertenregeln" verwendet.

Solche Regeln spielen in den beiden in Kapitel 5 analysierten Expertensystemen auf der Basis der Dempster-Shafer Theorie (DST) eine entscheidende Rolle, indem sie Evidenzen auf mit diesen kompatible Hypothesen abbilden und letzteren gleichzeitig eine numerische Bewertung zuweisen. Insofern stellen diese Ansätze eine Erweiterung der "klassischen" DST dar. Die Einordnung in die Theorie des evidenzbasierten Schließens verleiht dem allgemeineren beider Ansätze eine wahrscheinlichkeitstheoretische Semantik und bildet die Basis für die nachfolgende Behandlung der Planerkennung.

Kapitel 6 schließlich bildet den Kern der vorliegenden Arbeit. Hier wird erklärt, wie die Wissensquellen eines Planerkennters und die agentenspezifische Information innerhalb der DST repräsentiert und bei der Bewertung von Planhypothesen verwendet werden können. Dabei wird jeweils auf die Einbettung in die in Kapitel 4 vorgestellte und erweiterte Theorie des evidenzbasierten Schließens geachtet. Der Planerkennungsprozess selbst wird in verschiedenen Ausprägungen untersucht, wobei vor allem die Genauigkeit der möglichen Beobachtungen und die Anzahl der Beobachter eine Rolle spielen. Schließlich werden Aufbau und Wartung eines quantitativen Benutzermodells erläutert, bevor Spezialfälle der Planerkennung und die Komplexität der zugrundeliegenden Berechnungen betrachtet werden. Dabei werden unter anderem Algorithmen zur Approximation von Basiswahrscheinlichkeiten präsentiert und empirisch auf ihre Anwendbarkeit in der Entscheidungsfindung untersucht.

Die konkrete Anwendung des hier vorgestellten Planerkennungsansatzes im Rahmen der Projekte PHI und RAP in einem intelligenten Hilfesystem bzw. einer generischen Shell für Planungssysteme ist Inhalt des Kapitels 7. Dabei geht es vor allem um die Besonderheiten, die durch die Verwendung der Planungslogik LLP und die

Kopplung des Planerkenners mit einem deduktiven Plangenerierer auftreten, sowie um die Integration der vorgestellten Konzepte in eine flexible Planungsumgebung.

Kapitel 8 schließlich faßt die wesentlichen Ergebnisse dieser Arbeit zusammen und diskutiert mögliche Ansatzpunkte für Erweiterungen. Anhang A enthält einen Exkurs über die algebraische Charakterisierung maßfreier Konditionale und ergänzt somit Kapitel 4. Der Anhang B listet die wesentlichen Daten für das Anwendungsbeispiel aus Kapitel 7 auf.

Kapitel 2

Behandlung unsicheren und unvollständigen Wissens in der Dempster-Shafer Theorie

Dieses Kapitel gibt einen kurzen Überblick über die Grundbegriffe der *Dempster-Shafer Theorie* (DST) oder *Evidenztheorie*, soweit diese in den nachfolgenden Kapiteln benötigt werden. Zudem werden in diesem Zusammenhang einige wichtige wahrnehmungstheoretische Begriffe eingeführt, die speziell für die Diskussion in Kapitel 4 von Bedeutung sind.

Für eine detaillierte Einführung in das Gebiet der Wahrscheinlichkeitstheorie sei hier u.a. auf [Pearl, 1988], [Kruse *et al.*, 1991] und [Heinsohn, 1993] verwiesen. Eine kurze Einführung in die Grundlagen der Bayesschen Netze ist in [Charniak, 1991] zu finden. Eine ausführliche Übersicht über das Gebiet der Dempster-Shafer Theorie bieten neben den Originalarbeiten [Dempster, 1967] und [Shafer, 1976] u.a. [Kruse *et al.*, 1991], [Guan und Bell, 1991] und [Heinsohn, 1993]. Eine ausführliche Diskussion dieses Ansatzes bietet darüberhinaus die Sonderausgabe [JAPPR, 1992] des *Journal of Approximate Reasoning*.

2.1 Grundlagen der Dempster-Shafer Theorie

Sei Ω ein endlicher Ereignisraum (*frame of discernment*). Ziel ist es, durch Auswertung gegebener Evidenzen den unbekanntem tatsächlichen Weltzustand $\omega_0 \in \Omega$ zu identifizieren. Eine Teilmenge $A \subseteq \Omega$ des Ereignisraumes repräsentiert das Ereignis “ A enthält den gesuchten Zustand.” Ist beispielsweise $\Omega = \{1, \dots, 6\}$ die Menge aller möglichen Ergebnisse beim Werfen eines Würfels, so steht $A = \{1, 3, 5\}$ für das Ereignis “es wurde eine ungerade Zahl geworfen”, d.h. das tatsächliche Ergebnis ω_0 ist entweder 1, 3 oder 5.

Die Auswertung einer Evidenz erlaubt es, solchen Ereignissen – die auch als *Hypothesen* bzgl. des tatsächlichen Weltzustandes bezeichnet werden können – einen

numerischen Vertrauensgrad zuzuordnen. Sei dazu Θ ein endlicher *Evidenzenraum*, d.h. eine Menge von Beobachtern, die mittels einer *Kompatibilitätsabbildung* Γ eine Teilmenge von Ω als mit ihren Beobachtungen kompatibel identifizieren. Ist $\theta \in \Theta$ ein Beobachter mit $\Gamma(\theta) = A \subseteq \Omega$, so bedeutet dies, daß die von θ gemachte Beobachtung alle nicht zu A gehörenden Elemente von Ω als Kandidaten für ω_0 ausschließt. Jedoch kommen alle Elemente von A gleichermaßen als ω_0 in Frage (betrachtet man nur die durch θ gegebene Information). Liegt nun zusätzlich zu diesen Aussagen der Beobachter eine Wahrscheinlichkeitsverteilung P auf Θ vor, die die “Wichtigkeit” bzw. relative Zuverlässigkeit der einzelnen Beobachter quantifiziert, so ist es möglich, den Ereignissen in Ω , d.h. den Hypothesen bzgl. des Weltzustandes, einen Vertrauensgrad zuzuweisen:

Definition 2.1.1 (induzierte Massenverteilung, [Dempster, 1967])

Seien Θ und Ω wie oben, P eine Wahrscheinlichkeit auf Θ . Dann ist die Funktion $m_\Gamma : 2^\Omega \rightarrow [0, 1]$ mit

$$m_\Gamma(X) = \begin{cases} \frac{\sum_{\theta: \Gamma(\theta)=X} P(\{\theta\})}{\sum_{\theta: \Gamma(\theta) \neq \emptyset} P(\{\theta\})}, & X \neq \emptyset \\ 0, & \text{sonst} \end{cases}$$

die durch P und Γ induzierte Massenverteilung.

Anmerkungen:

1. Die Division durch die Summe der Wahrscheinlichkeiten aller θ mit $\Gamma(\theta) \neq \emptyset$ entspricht der Konditionierung bzgl. derjenigen Beobachter, die überhaupt etwas gemeldet haben.
2. $m_\Gamma(X)$ entspricht dem Grad des Vertrauens, der *genau* dem Ereignis X , mangels spezifischerer Information jedoch keiner Teilmenge von X zugeordnet werden kann. Vergleiche dazu auch die Diskussion in Abschnitt 4.1 und speziell 4.1.2.

In [Shafer, 1976] wird der Begriff der Massenverteilung aus Definition 2.1.1 ohne den “Umweg” einer mengenwertigen Funktion Γ zur Charakterisierung subjektiver Vertrauensgrade direkt durch Angabe zweier hinreichender und notwendiger Bedingungen unter dem Namen *Basiswahrscheinlichkeit* eingeführt.

Definition 2.1.2 (Basiswahrscheinlichkeit, [Shafer, 1976])

Sei Ω wie oben. Dann heißt eine Funktion $m : 2^\Omega \rightarrow [0, 1]$ mit

- $m(\emptyset) = 0$
- $\sum_{X \subseteq \Omega} m(X) = 1$

eine *Basiswahrscheinlichkeit* (“basic probability assignment, bpa”).

Anmerkung: Diejenigen Teilmengen $X \subseteq \Omega$ mit $m(X) > 0$ werden als die *Fokalelemente von m* bezeichnet.

Eine solche Basiswahrscheinlichkeit verallgemeinert eine diskrete Wahrscheinlichkeitsverteilung insofern, als sie auch nicht-elementaren Ereignissen, d.h. mehrelementigen Teilmengen von Ω , direkt einen positiven numerischen Wert zuweist, was in der Modellierung partieller und sogar totaler Unwissenheit Verwendung findet. Ist eine gegebene Evidenz spezifisch genug, ein Elementarereignis zu identifizieren, etwa “der letzte Wurf des Würfels ergab eine 3”, so kann dies modelliert werden durch eine Basiswahrscheinlichkeit m mit $m(\{3\}) = 1$ und Null für alle anderen Ereignisse. Erlaubt die Evidenz hingegen lediglich, die Menge der möglichen Ereignisse einzuschränken, etwa durch die Aussage “es wurde eine ungerade Zahl geworfen”, so ergibt sich eine Abbildung m mit $m(\{1, 3, 5\}) = 1$ und Null sonst. Im Gegensatz zur Wahrscheinlichkeitstheorie ist es hier *nicht* notwendig, den Teilmengen von $\{1, 3, 5\}$ ebenfalls einen positiven Wert zuzuordnen. Dies repräsentiert die Tatsache, daß die Evidenz keine direkten Hinweise auf diese spezifischeren Ereignisse enthielt. Im Extremfall ergibt sich die sogenannte “leere Basiswahrscheinlichkeit” \tilde{m} mit $\tilde{m}(\Omega) = 1$ und Null für alle anderen Ereignisse. Für das gegebene Beispiel mit $\Omega = \{1, \dots, 6\}$ repräsentiert diese Basiswahrscheinlichkeit die Evidenz “der Würfel wurde geworfen (das Ergebnis ist jedoch unbekannt).”

Aus einer Basiswahrscheinlichkeit können folgende Funktionen eindeutig abgeleitet werden:

Definition 2.1.3 (Belief, Plausibilität)

Sei $m : 2^\Omega \rightarrow [0, 1]$ eine Basiswahrscheinlichkeit. Dann heißen die Funktionen $Bel_m, Pl_m : 2^\Omega \rightarrow [0, 1]$ mit

$$Bel_m(A) = \sum_{B: B \subseteq A} m(B)$$

$$Pl_m(A) = \sum_{B: B \cap A \neq \emptyset} m(B)$$

die durch m induzierte *Belief-* bzw. *Plausibilitätsfunktion*. Wenn die zugrundeliegende Basiswahrscheinlichkeit m klar ist, wird auf den Index jeweils verzichtet.

Während $m(X)$, wie bereits erwähnt, den Vertrauensgrad quantifiziert, der *genau* X zugeordnet werden kann, repräsentiert $Bel_m(X)$ den Gesamtvertrauensgrad in X (und alle seine Teilmengen). Demgegenüber ist $Pl_m(X)$ der Teil der numerischen *Evidenzmasse*, der bei zusätzlicher Information noch potentiell an X zugewiesen werden könnte (siehe Definition 2.1.4). Vergleiche dazu wiederum Abschnitt 4.1.

Anmerkungen:

1. $Bel_m(X) \leq Pl_m(X)$.
2. $Pl_m(X) = 1 - Bel_m(\overline{X})$.

Satz 2.1.1 Eine Funktion $Bel : 2^\Omega \rightarrow [0, 1]$ ist eine Belief-Funktion genau dann, wenn

- $Bel(\emptyset) = 0$
- $Bel(\Omega) = 1$
- $Bel\left(\bigcup_{i=1}^n A_i\right) \geq \sum_{I:\emptyset \neq I \subseteq \{1, \dots, n\}} (-1)^{|I|+1} \cdot Bel\left(\bigcap_{i \in I} A_i\right)$

für alle $n \in \mathbb{N}$ und alle $A_1, \dots, A_n \subseteq \Omega$.

Anmerkung: Der numerische Wert $Pl_m(A) - Bel_m(A)$, d.h. die Größe des einem Ereignis A zugeordneten Vertrauensintervalls, wird als der *Grad der Unwissenheit* bzgl. A bezeichnet. Im Falle der leeren Basiswahrscheinlichkeit \tilde{m} ist dieser maximal, da dann für alle Ereignisse $A \subset \Omega$ gilt: $Bel_{\tilde{m}}(A) = 0$ und $Pl_{\tilde{m}}(A) = 1$.

Die Dempster-Shafer Theorie stellt einen Mechanismus zur Verfügung, der die Kombination zweier voneinander unabhängiger Evidenzen in Form von Basiswahrscheinlichkeiten erlaubt.

Definition 2.1.4 (Dempsters Regel)

Seien $m_1, m_2 : 2^\Omega \rightarrow [0, 1]$ zwei Basiswahrscheinlichkeiten. Dann ist ihre *Kombination* $m_1 \oplus m_2$ definiert als

$$m_1 \oplus m_2 : 2^\Omega \rightarrow [0, 1]$$

$$A \mapsto \begin{cases} \frac{\sum_{B_1, B_2: B_1 \cap B_2 = A} m_1(B_1) \cdot m_2(B_2)}{\sum_{B_1, B_2: B_1 \cap B_2 \neq \emptyset} m_1(B_1) \cdot m_2(B_2)}, & A \neq \emptyset \\ 0, & \text{sonst} \end{cases}$$

Wird der Nenner in obiger Gleichung Null, so widersprechen sich die in m_1 und m_2 kodierten Informationen vollständig, d.h. es existieren keine Ereignisse (Teilmengen von Ω), die durch *beide* Evidenzen unterstützt werden. In diesem Fall ist die Kombination von m_1 und m_2 undefiniert. Ansonsten dient diese Division der Normalisierung der erhaltenen numerischen Werte – wodurch auch $m_1 \oplus m_2$ wieder zu einer Basiswahrscheinlichkeit wird – und beseitigt als Nebeneffekt partielle Konflikte zwischen beiden Informationsquellen. Das heißt, die gesamte numerische Masse wird unter denjenigen Ereignissen verteilt, die von beiden Evidenzen unterstützt werden.

2.2 Exkurs: Klassen von Wahrscheinlichkeiten

Dieser Abschnitt führt einige wichtige Begriffe aus dem Bereich der Wahrscheinlichkeitstheorie ein, die im Zusammenhang mit einer probabilistischen Charakterisierung der Dempster-Shafer Theorie in Kapitel 4 von Bedeutung sind.

Sei Ω eine endliche Menge von *Elementarereignissen*. Teilmengen von Ω sollen *Ereignisse* repräsentieren. Dabei steht Ω selbst für das sichere, die leere Menge \emptyset für das unmögliche Ereignis. Die Gesamtheit aller Ereignisse bildet eine Teilmengenalgebra \mathcal{E} von Ω .

Definition 2.2.1 (Ereignisraum, Wahrscheinlichkeitsraum)

Das Tupel (Ω, \mathcal{E}) heißt *Ereignisraum*. Gilt $\mathcal{E} = 2^\Omega$, so wird auch Ω selbst als Ereignisraum bezeichnet. Ist P eine Wahrscheinlichkeit auf \mathcal{E} , so heißt (Ω, \mathcal{E}, P) *Wahrscheinlichkeitsraum*.

Ist (Ω, \mathcal{E}, P) ein Wahrscheinlichkeitsraum mit $\mathcal{E} \neq 2^\Omega$, so ist die Wahrscheinlichkeit P nicht für alle Teilmengen von Ω definiert (die Elemente von \mathcal{E} , für die dies jedoch der Fall ist, heißen *meßbare Ereignisse*). P kann allerdings auf die gesamte Potenzmenge 2^Ω ausgeweitet werden.

Definition 2.2.2 (untere, obere Wahrscheinlichkeit)

Sei (Ω, \mathcal{E}, P) ein Wahrscheinlichkeitsraum. Dann heißen die Funktionen $P_*, P^* : 2^\Omega \rightarrow [0, 1]$ mit

$$\begin{aligned} P_*(A) &= \sup\{P(X) \mid X \subseteq A \text{ und } X \in \mathcal{E}\} \\ P^*(A) &= \inf\{P(X) \mid X \supseteq A \text{ und } X \in \mathcal{E}\} \end{aligned}$$

die durch P induzierte untere bzw. obere Wahrscheinlichkeit von A .

Anmerkung: Mitunter werden P_* und P^* auch als innere und äußere Wahrscheinlichkeit bezeichnet.

Lemma 2.2.1 *Untere und obere Wahrscheinlichkeiten besitzen u.a. folgende Eigenschaften:*

(U1) $P_*(A) = 1 - P^*(\bar{A})$

(U2) $P_*(\emptyset) = 0$

(U3) $P_*(\Omega) = 1$

(U4) $P_*(A_1 \cup \dots \cup A_n) \geq \sum_{\emptyset \neq I \subseteq \{1, \dots, n\}} (-1)^{|I|+1} P_*(\bigcap_{i \in I} A_i)$

Vor allem im Zusammenhang mit der Diskussion der Dempster-Shafer Theorie spielen *Klassen* von Wahrscheinlichkeiten eine wichtige Rolle.

Definition 2.2.3 (untere, obere Schranke)

Sei \mathcal{L} eine Klasse von Wahrscheinlichkeiten. Dann heißen die Funktionen $P_{\mathcal{L}^*}$ und $P_{\mathcal{L}^*}^* : 2^\Omega \rightarrow [0, 1]$ mit

$$\begin{aligned} P_{\mathcal{L}^*}(A) &= \inf\{P(A) \mid P \in \mathcal{L}\} \\ P_{\mathcal{L}^*}^*(A) &= \sup\{P(A) \mid P \in \mathcal{L}\} \end{aligned}$$

die *untere und obere Schranke* von \mathcal{L} .

Definition 2.2.4 (Typ 1)

Sei \mathcal{L} eine Klasse von Wahrscheinlichkeiten über einem Ereignisraum Ω . \mathcal{L} ist *vom Typ 1*, wenn es Funktionen $R_1, R_2 : 2^\Omega \rightarrow [0, 1]$ gibt, so daß

$$\mathcal{L} = \{P \mid \forall A \subseteq \Omega : R_1(A) \leq P(A) \leq R_2(A)\}.$$

Werden die Funktionen R_1 und R_2 willkürlich gewählt, so ist es möglich, daß die Menge aller durch diese beschränkten Wahrscheinlichkeitsfunktionen leer ist.

Definition 2.2.5 (Typ 2)

Sei \mathcal{L} eine Klasse vom Typ 1. Dann ist \mathcal{L} *vom Typ 2*, wenn für jede ganze Zahl n und alle Ereignisse A_1, \dots, A_n gilt:

$$P_{\mathcal{L}^*}(A_1 \cup \dots \cup A_n) \geq \sum_{\emptyset \neq I \subseteq \{1, \dots, n\}} (-1)^{|I|+1} P_{\mathcal{L}^*}\left(\bigcap_{i \in I} A_i\right)$$

Vergleicht man dies mit Definition 2.2.2, so zeigt sich, daß jede untere Wahrscheinlichkeit P_* die untere Schranke einer Klasse vom Typ 2 ist. Die entsprechende obere Wahrscheinlichkeit P^* ist die obere Schranke derselben Klasse. Ein Beispiel für eine solche Klasse ist die Menge aller *Erweiterungen* einer Wahrscheinlichkeit (siehe dazu Satz 4.1.5 und die anschließende Diskussion).

Offensichtlich entspricht die Charakterisierung von Belief-Funktionen gemäß Satz 2.1.1 exakt den Eigenschaften der unteren Wahrscheinlichkeit einer Klasse von Wahrscheinlichkeiten vom Typ 2 (vergleiche dazu Definition 2.2.5). Entsprechend können die dazu dualen Plausibilitätsfunktionen als obere Wahrscheinlichkeiten betrachtet werden. In diesem Sinne stellt eine Basiswahrscheinlichkeit m eine kompakte Repräsentation einer solchen Klasse von Wahrscheinlichkeiten dar. Die induzierten *Vertrauensintervalle* $[Bel_m(A), Pl_m(A)]$ schränken die unbekannte Wahrscheinlichkeit eines Ereignisses A nach oben und unten ein. Diese Identifizierung von Konzepten der Dempster-Shafer Theorie mit probabilistischen Funktionen wird allgemein von Vertretern der DST abgelehnt (vergleiche u.a. die Diskussion in [JAPPR, 1992], speziell [Shafer, 1992]). In welchem Sinne die gegebene formale Übereinstimmung sich auch semantisch widerspiegelt, wird in Kapitel 4, speziell in Abschnitt 4.1 behandelt.

Kapitel 3

Ansätze zur Hypothesenbewertung in der Planerkennung

Dieses Kapitel stellt verschiedene Ansätze zur Lösung des Problems der Behandlung mehrerer gleichermaßen plausibler Planhypothesen eines Planerkenners vor. Dieses stellt sich immer dann, wenn eine *Menge* von Hypothesen mit allen bisher gemachten Beobachtungen kompatibel ist und somit der aktuell verfolgte Plan ohne Zuhilfenahme zusätzlicher Information nicht eindeutig identifiziert werden kann. Die Berechnung einer *Bewertung der Qualität* der verschiedenen Hypothesen wird einerseits zur Effizienzsteigerung des Planerkennungsprozesses genutzt – indem schlecht bewertete Hypothesen direkt verworfen oder aber erst zu einem späteren Zeitpunkt wieder behandelt werden – andererseits aber auch zur Unterstützung der Entscheidungsfindung, wenn beispielsweise in einem Hilfesystem der Planerkenner aufgefordert wird, seine beste Hypothese über den tatsächlichen Plan des Benutzers auszugeben.

Die dabei zum Einsatz kommenden Techniken reichen von ATMS (“Assumption-Based Truth Maintenance System”) mit numerischer Bewertung von Kontexten über wahrscheinlichkeitstheoretische Ansätze bis zur Verwendung informationstheoretischer Maße und der Dempster-Shafer Theorie.

3.1 ATMS-basierte Systeme

Eines der zentralen Probleme in der Planerkennung ist die Verwaltung der Menge aller Planhypothesen, die mit den bisherigen Beobachtungen kompatibel waren. Alle in diesem Abschnitt vorgestellten Systeme tun dies mit Hilfe eines ATMS [de Kleer, 1986a; de Kleer, 1986b], in dem jeder einzelne Kontext – d.h. jede Menge nichtmonotoner Annahmen, die eine Anzahl von Schlüssen rechtfertigen – eine der sich gegenseitig ausschließenden Planhypothesen repräsentiert.

Wimp2 und IPS berechnen eine numerische Bewertung der einzelnen Hypothesen

aus den “Wahrscheinlichkeiten” ihrer jeweiligen Kontexte. Eine Ausnahme dazu bildet NP, das eine mehrwertige Logik mit symbolischen Wahrheitswerten zur Beurteilung von Aussagen bzgl. Planhypothesen verwendet.

3.1.1 Das System Wimp2

Die Aufgabe des Wimp2-Systems (siehe [Goldman und Charniak, 1988]) zum Verstehen natürlichsprachlicher Geschichten ist es, seine Eingabe – 1-3 Sätze – in eine logische Form zu übertragen und Schlüsse bzgl. ihrer kausalen und planbezogenen Struktur zu ziehen. Die Grundlage dafür bildet ein ATMS, dessen verschiedene Kontexte jeweils unterschiedliche Erklärungen der aktuellen Eingabe repräsentieren. Diese werden probabilistisch bewertet, was sowohl eine Begrenzung des Suchraumes ermöglicht, als auch ein Kriterium zur Auswahl der “besten” Hypothesen bietet.

Die Motivation für dieses Konzept war die Beobachtung, daß

- frühe Planerkenner wie PAM [Wilensky, 1978] und BRUIN [Wong, 1981] zum “Over-commitment” neigten, d.h. daß beim Auftreten mehrerer Hypothesen willkürlich eine ausgewählt werden mußte, mit der dann weitergearbeitet wurde, und
- Planerkenner, die Markierungen durch semantische Netze propagieren, wie etwa das Vorgängersystem Wimp (siehe [Charniak, 1986]), zwar mit multiplen Hypothesen umgehen können, jedoch ein konventionelles TMS benutzen, wodurch ein Konsistenztest eine erneute Propagierung aller Markierungen für jede Hypothese erforderlich macht. Diese Systeme neigen zum “Under-commitment”, d.h. alle noch kompatiblen Hypothesen werden solange aufrechterhalten, bis ihre Inkonsistenz mit der aktuellen Eingabe gezeigt werden kann. Dies bringt einen erheblichen Rechenaufwand mit sich.

Bei der Entwicklung von Wimp2 als vorwärtsverkettendes System mit einem probabilistischen ATMS wurden speziell folgende Probleme berücksichtigt:

1. Wie kann Under-commitment durch Angabe eines Auswahlkriteriums verhindert werden?
2. Wie kann man den Suchraum der möglichen Erklärungen beschränken?
3. Wie können die Ergebnisse der Konsistenzchecks der einzelnen Hypothesen zwischengespeichert werden, um im nächsten Schritt nicht von vorne beginnen zu müssen?
4. Wie können aufwendige Neuberechnungen vermieden werden, wenn sich herausstellt, daß mehr als ein Plan gleichzeitig verfolgt wird?

Die beiden ersten Punkte werden durch die probabilistische Bewertung der verschiedenen Kontexte behandelt, wobei Kontexte mit niedriger Bewertung vorerst nicht weiter betrachtet werden (“lazy forward-chaining”). Dies erlaubt es dem System zu verfahren, als hätte es sich bereits für eine Erklärung entschieden, ohne jedoch die Alternativen zu verwerfen.

Die mehrfachen Kontexte des ATMS bilden den Zwischenspeicher für die Ergebnisse der Konsistenztests und erlauben, Beobachtungen gleichzeitig sowohl einer einzigen, als auch mehreren verschiedenen Planinstanzen zuzuordnen. Somit können die in den Punkten 3. und 4. angesprochenen Probleme gelöst werden.

Der Verkettungsmechanismus von Wimp2 besteht aus einer einzigen Regel:

```
(-> (inst ?x ?frame)
    (or (previously-exists ?p-inst.?frame (= ?x ?p-inst))
        (->or (role-inst ?frame ?slot ?superframe)
              (exists ?s.?superframe (= (?slot ?s) ?x))))),
```

die wie folgt zu interpretieren ist:

“Wird eine Aussage gemacht, daß ?x vom Typ ?frame ist (d.h. wird ein entsprechender Eintrag im ATMS vorgenommen), dann

1. schließe daraus, daß ?x mit einer bereits existierenden Instanz ?p-inst vom gleichen Typ identisch ist (falls es eine solche gibt) **oder**
2. falls es einen Slot ?slot in einem Konzept ?superframe gibt, der mit Objekten vom Typ ?frame gefüllt werden kann, dann kreiere ein neues Objekt ?s vom Typ ?superframe, dessen Slot ?slot mit ?x gefüllt ist.”

Gibt es in 1. mehrere solcher Objekte, so wird ein sogenannter `previously-exists`- oder “choose”-Knoten, d.h. eine Disjunktion der entsprechenden Gleichheitsannahmen, in das ATMS eingetragen. Analog verzweigen von einem `->or`-Knoten (Fall 2.) die Kanten zu den zugehörigen Aussagen bzgl. der Rollenfüller. Abbildung 3.1 verdeutlicht dieses Vorgehen. Dabei stellen die doppelt umrandeten Knoten Disjunktionen ihrer Nachfolger dar. Eingabe des Systems ist in diesem Fall der folgende Text.

“Jack got a rope. He wanted to kill himself.”

Zunächst muß die Aktion des ersten Satzes erklärt werden. Dazu wird die Disjunktion aller Pläne, die eine solche Aktion (“get”) beinhalten, in das ATMS eingetragen. Beispiele dafür sind etwa “Seilspringen” oder “Erhängen”. In den Knoten des ATMS werden die konkreten Instanzen dieser Pläne durch die Skolem-Konstanten `jump-rope35` und `make-noose33` repräsentiert. Bei der Verarbeitung des Wortes “rope” wird der Eintrag `(inst rope-27 rope)` im ATMS eingefügt. Dabei entspricht der Name wiederum einer Skolem-Konstanten. Um nun dieses neu erwähnte Seil mit diesen Plänen in Verbindung zu bringen, werden folgende Möglichkeiten betrachtet. `rope-27` könnte

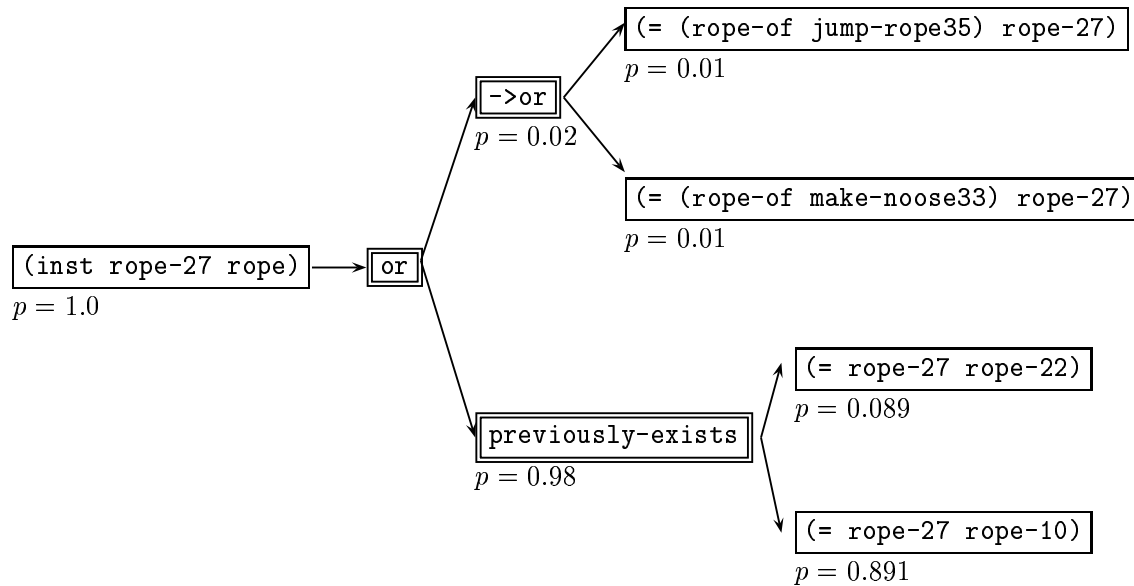


Abbildung 3.1: Aussagenbaum im ATMS nach Eingabe von `(inst rope-27 rope)`.

sowohl identisch sein mit den bereits existierenden Seilen `rope-22` und `rope-10`, als auch den entsprechenden Rollenfüllern der Pläne `make-noose33` und `jump-rope35`, die offensichtlich die Verwendung eines Objektes von diesem Typ vorsehen, darstellen.

Wimp2 verwaltet die Wahrscheinlichkeiten der entstehenden Kontexte, indem es einen Baum solcher Oder-Knoten aufbaut, wobei die tatsächlichen numerischen Werte für diese Knoten vom Benutzer abgefragt werden. Zur Bewertung von `->or`- und `previously-exists`-Knoten werden verschiedene Heuristiken verwendet, um die errechneten Werte an die folgenden Intuitionen anzupassen:

- Wann immer es möglich ist, werden bereits erwähnte Objekte zur Erklärung einer neuen Aussage herangezogen.
- Eine spezifischere Erklärung wird einer allgemeineren vorgezogen. Dies bezieht sich etwa auf die Spezifikation des Typs eines Rollenfüllers. Instanzen, bei denen ein Slot mit restriktiverer Typspezifikation gefüllt werden kann, werden bevorzugt.

Dies führt zu folgendem Vorgehen:

1. Wahrscheinlichkeiten an `or`-Knoten werden explizit vom Benutzer gesetzt. Sie ändern sich nur im Zuge einer Renormalisierung, wenn der zu einem der Kinder gehörende Kontext – d.h. die Menge aller Annahmen, auf denen die Richtigkeit dieser Aussage beruht – als inkonsistent identifiziert wurde. Dies wird auch als “Nogood” bezeichnet. Im Beispiel wurde 0.98 als Wahrscheinlichkeit dafür gewählt, daß die neue Aussage durch eine Referenz auf eine alte Instanz erklärt

wird, und 0.02 dafür, daß ein Slot einer neuen Instanz gefüllt wird. Die Technik des lazy forward-chaining wird diese Möglichkeit vorerst nicht weiter verfolgen, solange die erste Alternative nicht verworfen wird.

2. Zur Markierung von *->or*-Knoten werden sowohl Benutzereingaben bzgl. relativer Wahrscheinlichkeiten (z.B. gemessen an der Qualität der Übereinstimmung der Evidenz mit den Vorgaben des Plans) verwendet, als auch die Markierungen der Kinder, die diese durch Querverbindungen (sog. "link-ups") zu bereits existierenden Instanzen erhalten haben.
3. Bei *previously-exists*-Knoten werden die Wahrscheinlichkeiten entsprechend dem Alter der betreffenden Instanzen verteilt, wobei ältere bevorzugt werden.

Kritik:

Während die verwendeten numerischen Werte und Berechnungsmethoden einerseits den Suchprozeß korrekt steuern, so gibt es doch Probleme in ihrer probabilistischen Interpretation. Die Wahrscheinlichkeit einer Aussage ist definiert als die Summe der Wahrscheinlichkeiten ihrer Kontexte. Um aber die Korrektheit dieser Wahrscheinlichkeiten garantieren zu können, müssen die Werte für Annahmen so gewählt werden, daß sie nicht bedingten Wahrscheinlichkeiten bzgl. der Evidenz entsprechen, sondern vielmehr die relative Veränderung dieser Wahrscheinlichkeit bei Hinzunahme der Evidenz widerspiegeln.

3.1.2 Das System NP

Eine ähnliche Motivation wie bei Wimp2 liegt der Entwicklung von NP (Natural language Plan inference system) zugrunde (siehe [Myers, 1989; Myers, 1990; Myers, 1991]). Die Anwendungsdomäne ist das Verstehen von Dialogen in natürlicher Sprache.

Ein zentrales Anliegen dabei ist die explizite Modellierung von *Annahmen* – im Gegensatz zu *Fakten* –, die bei der Dialogführung und ebenso bei der Planerkennung eine Rolle spielen. Beispiele solcher Annahmen betreffen den Wissensstand des Dialogpartners oder dessen Bereitschaft zur Kooperation bei der Mitteilung von Information. Ihre explizite Repräsentierung ist notwendig, um eventuell auftretende Inkonsistenzen durch Rücknahme einer entsprechenden Aussage zu beheben oder den Vertrauensgrad in das tatsächliche Auftreten einer Aktion bzw. eines Effektes zu quantifizieren.

Die dazu verwendeten Wahrheitswerte sind *actual*, *possible*, *hypothetical* und *inconsistent*. Die Berechnung und Propagierung solcher Werte wird durch ein ATMS vorgenommen, das um die Möglichkeit der Operation mit dieser mehrwertigen Logik erweitert wurde.

Das System verarbeitet einen Dialog, indem zunächst in einer Initialisierungsphase "wichtige" Zustände und Aktionen als Knoten in das ATMS eingetragen und mit *hypothetical* markiert werden. Dadurch wird eine Fokussierung auf potentiell vielversprechende Hypothesen vorgenommen. Die einzelnen Aussagen des Dialogs werden

nacheinander durch Hinzufügen neuer Knoten in das ATMS abgearbeitet. Ihr Wahrheitswert wird je nach Vertrauen in die Richtigkeit entweder auf *actual* oder *hypothetical* gesetzt. Unter Berücksichtigung der zugrundeliegenden Regeln der mehrwertigen Logik werden die Effekte der entsprechenden Aktionen mit ihrem zugehörigen Wahrheitswert in das ATMS aufgenommen und dienen zur Vorhersage weiterer Aktionen. Bei auftretenden Inkonsistenzen werden die Mechanismen des ATMS verwendet, diese durch Entfernen der dafür verantwortlichen Annahmen aufzulösen.

Der einem Dialog zugrundeliegende Plan wird dadurch erkannt, daß alle Vorbedingungen der mit einer Äußerung assoziierten Aktion sowie alle ihre Teilschritte – ihre “Dekomposition” – durch Beobachtung oder Ableitung im ATMS bestätigt und die Effekte dieser Aktion mit dem entsprechenden Wahrheitswert in das ATMS eingetragen werden. Da Vorbedingungen oftmals auf mentale Zustände verweisen, sind diese eine Quelle der Unsicherheit im ATMS. Diese dienen zur Vorhersage der nachfolgenden Aktionen, bilden somit also die zu bestätigenden Hypothesen für die nächsten Äußerungen im Dialog, und stellen die Verbindung zum übergeordneten Ziel des Planes her.

Kritik:

Dieses System ist in der Lage, unsichere Evidenzen zu verarbeiten und mehrere Planhypothesen gleichzeitig zu verfolgen. Jedoch hat es keine Möglichkeit, die “Qualität” der einzelnen Hypothesen zu bewerten – und somit gegebenenfalls eine davon frühzeitig auszuwählen – oder die Wahrscheinlichkeit einer Situation zu bewerten. Es kann lediglich zwischen tatsächlich zutreffenden und hypothetisch möglichen Aussagen unterscheiden. Auch ist es nicht in der Lage, mit partiell fehlender Information umzugehen. Die Erkennung einer Aktion setzt die Bestätigung aller Vorbedingungen und die Beobachtung aller elementaren Teilschritte voraus.

3.1.3 Das System IPS

ATMS-Techniken werden ebenso im System IPS (Integrated Plans and Scripts) (siehe [Benoit *et al.*, 1988]) zur simultanen Verwaltung mehrerer Hypothesen verwendet. Die Anwendungsdomäne des “Schlachtenmanagement” bringt verschiedene spezifische Anforderungen mit sich.

- Es werden große Mengen unzusammenhängender Daten (Reports) empfangen.
- Diese sind mit Fehlern und Mehrdeutigkeiten behaftet.
- Die Reports stammen von unterschiedlichen Sensoren und sind somit unterschiedlich zu bewerten.
- Viele Ereignisse haben eine spezifische Dauer, die für die Erkennung eines Planes von Bedeutung ist.

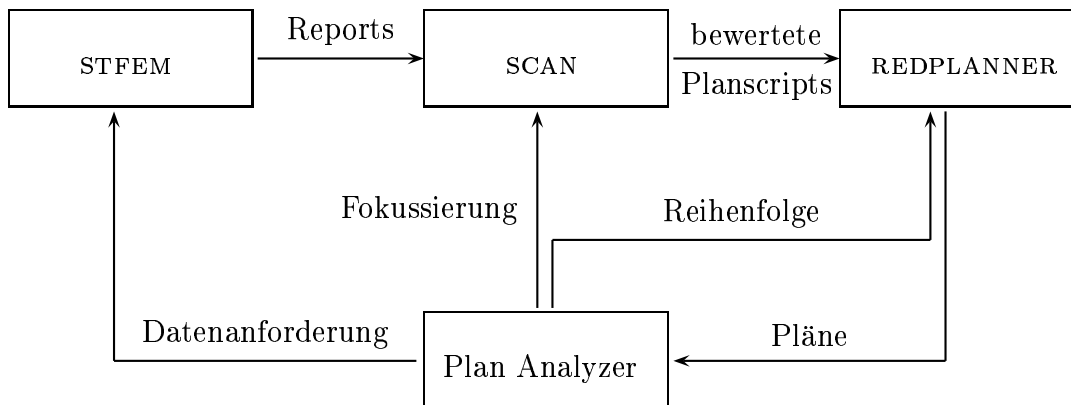


Abbildung 3.2: Die Architektur von IPS.

- Aufgrund der Mehrdeutigkeit der Situation müssen mehrfache Hypothesen aufrechterhalten und frühere Reports u.U. neu evaluiert werden.

Der Ablauf der Planerkennung ist folgender (siehe auch Abbildung 3.2): SCAN matcht die aufbereiteten Sensordaten gegen eine Menge von Planscripts (stereotypische Repräsentationen von Aktionssequenzen mit einem assoziierten Ziel) und erhält so eine Anzahl möglicher Ziele. Jedes Script erhält eine numerische Bewertung, die sowohl die geschätzte Zuverlässigkeit der zur Verfügung stehenden Daten als auch die Anzahl und Güte der Übereinstimmungen von Reports und Scripts berücksichtigt.

Erfolgreich gematchte Scripts werden zusammen mit ihrem Report an den hierarchischen Planer REDPLANNER übergeben, der daraus situationsabhängige Pläne für die assoziierten Ziele erzeugt. Diese werden in einem ATMS verwaltet und inkrementell mit neuen Beobachtungen verfeinert.

Der Plan Analyzer vergleicht diese Pläne und berechnet eine Reihenfolge entsprechend ihrer "Wahrscheinlichkeit". Außerdem extrahiert er zukünftige Aktionen, deren Beobachtung eine Fokussierung auf bestimmte Pläne und somit eine Einschränkung des Suchraumes erlaubt und als zusätzliche Information zum Matching in SCAN verwendet wird. Der Simulator STFEM (Soviet Tactical Forces Environment Model) liefert im Prototypen die benötigten Daten.

Kritik:

Der gesamte Planerkennungsprozeß inklusive der Abschätzung der Zuverlässigkeit der verschiedenen Reports beruht auf einer Reihe von Heuristiken. Ebenso besitzt das zugrundeliegende numerische Modell keine formale Basis, wodurch getroffene Entscheidungen nur sehr schwer gerechtfertigt werden können, was gerade in einer sicherheitskritischen Anwendung, wie sie hier verfolgt wird, von großer Bedeutung wäre.

3.2 Probabilistische Ansätze

In diesem Abschnitt werden Systeme vorgestellt, deren zugrundeliegendes numerisches Unsicherheitsmodell auf der klassischen Wahrscheinlichkeitstheorie aufbaut, und die im Gegensatz zu den in Abschnitt 3.1 beschriebenen *kein* ATMS verwenden.

Während der Ansatz von Calistri-Yeh auf einem relativ einfachen graph-basierten Verfahren zur Best-first Suche unter Verwendung eines probabilistischen Benutzermodells beruht, basiert das anschließend beschriebene Wimp3-System auf dynamisch generierten Bayesschen Netzen.

3.2.1 Planerkennung mit einem probabilistischen Benutzermodell

Das Anliegen des in [Calistri, 1990; Calistri-Yeh, 1991] vorgestellten Ansatzes zur Planerkennung ist es, diese *robuster* zu machen in dem Sinn, daß Fehler des Benutzers während der Planausführung, die auf falschen Vorstellungen bzgl. bestimmter Gegebenheiten beruhen, die Erkennung des eigentlich verfolgten Planes nicht verhindern. Der Grund für solche Fehler kann z.B. die falsche Einschätzung des Effektes einer Aktion in einer bestimmten Situation sein (was dazu führen kann, daß diese "falsche" Aktion ausgeführt wird) oder die falsche Annahme, daß eine gewisse Vorbedingung, die für die erfolgreiche Anwendung einer Aktion notwendig ist, erfüllt ist. In dieser Diskussion soll jedoch in erster Linie die Verwendung eines *probabilistischen Benutzermodells* betrachtet werden, mit dessen Hilfe der Suchprozeß gesteuert wird.

Basis für die Planerkennung ist eine Planhierarchie, die als Und/Oder-Graph organisiert ist und alle möglichen Pläne sowie deren Dekomposition in Teilpläne und elementare Aktionen beinhaltet. Dabei stehen die Kinder eines Oder-Knotens x_o für Alternativen zum Erreichen des x_o zugeordneten Planes, während alle mit den Kindern eines Und-Knotens x_u assoziierten Aktionen ausgeführt werden müssen, um den durch x_u repräsentierten Plan erfolgreich abzuarbeiten. Ziel ist es, mit Hilfe eines modifizierten A*-Algorithmus einen Pfad durch diesen Graphen zu finden, der alle in einem natürlichsprachlichen Dialog erwähnten Aktionen enthält.

Ein *probabilistisches Benutzermodell* über einer solchen Planhierarchie besteht aus einer Menge bedingter Wahrscheinlichkeiten, mit denen die Kanten des Und/Oder-Graphen markiert sind. Sie repräsentieren die relative Wahrscheinlichkeit, daß ein Knoten gewählt wird unter der Voraussetzung, daß sein Vater im Graphen bereits ausgewählt wurde.¹

Für die Kinder x_1, \dots, x_n eines Und-Knotens x_u gilt dabei

$$P(x_i|x_u, W) = 1, \quad i = 1, \dots, n,$$

da jeder Teilschritt x_i notwendig für x_u ist, wobei W das aktuelle Weltwissen bezeichnet. D.h hat sich der Agent zur Ausführung des durch x_u repräsentierten Planes

¹Eine weitere konditionierende Bedingung ist das Weltwissen, auf dessen Rolle noch eingegangen wird.

entschieden, so muß er *alle* Teilschritte x_1, \dots, x_n ebenfalls durchführen. Sind x_1, \dots, x_n hingegen Kinder eines Oder-Knotens x_o , so gilt

$$\sum_{i=1}^n P(x_i|x_o, W) = 1,$$

da diese eine vollständige Menge sich gegenseitig ausschließender Alternativen zur erfolgreichen Ausführung des mit x_o assoziierten Planes darstellen.

Die akkumulierten Wahrscheinlichkeiten auf partiellen Pfaden durch die Planhierarchie dienen als Entscheidungskriterium dafür, welche Alternativen weiterverfolgt und expandiert werden sollen. Um diese Wahrscheinlichkeiten berechnen zu können, müssen verschiedene Annahmen gemacht werden wie z.B.

Wenn x ein Vorgänger von y und y der Vater von z ist, und wenn x , y und z alle auf einem gültigen Pfad liegen, dann gilt

$$P(z|x, y, Q, W) = P(z|y, Q, W)$$

für alle anderen Schritte Q .²

Die Wahrscheinlichkeit eines Pfades \overline{rx} , der in r beginnt und in x endet, ist die Wahrscheinlichkeit dafür, daß alle Knoten entlang dieses Pfades gewählt wurden:

$$P(\overline{rx}) := P(r, \dots, x).$$

Kritik:

Obwohl in der theoretischen Beschreibung des Vorgehens immer wieder darauf hingewiesen wird, daß das aktuelle Weltwissen W bei der numerischen Bewertung der einzelnen Pläne nicht außer acht gelassen werden darf, macht das implementierte System mehrere sehr starke vereinfachende Annahmen. Diese erlauben die Angabe der benötigten Werte, was unter Berücksichtigung von W i.a. nicht praktikabel gewesen wäre. Diese Annahmen sind im einzelnen:

- Sind y und z Kinder eines Oder-Knotens x , und können die beiden Kanten \overline{xy} und \overline{xz} beide Teil einer konsistenten Erklärung sein (d.h. eines Pfades, der alle erwähnten Konzepte umfaßt und alle Constraints erfüllt), dann gilt

$$\frac{P(y|x, W)}{P(z|x, W)} = \frac{P(y|x)}{P(z|x)}.$$

²Ein Plan bzw. ein ihm entsprechender Pfad durch den Suchgraphen heißt *gültig*, wenn er keine Mißkonzeptionen wie z.B. überflüssige oder "falsche" Aktionen enthält. Während die vorliegende Diskussion sich auf das Problem der "perfekten Erkennung" gültiger Pläne bezieht, ist die Behandlung solcher strukturellen Abweichungen in der Planausführung durch den Agenten ein weiterer Schwerpunkt von [Calistri, 1990].

- Unter der Annahme, daß jeder Pfad in der Hierarchie immer konsistent ist, d.h. daß alle mit den auf diesem Pfad liegenden Knoten assoziierten Constraints in W erfüllt sind, gilt

$$P(y|x, W) = P(y|x).$$

Der Tatsache, daß diese Annahme unrealistisch ist, wird dadurch Rechnung getragen, daß die Wahrscheinlichkeit eines inkonsistenten Pfades auf 0 gesetzt und alle anderen Werte am Ende der Planerkennung normalisiert werden, wodurch wieder der korrekte Wert erreicht wird. Dies ist jedoch nur möglich, wenn *alle* konsistenten Pfade gesucht werden, die die Eingabe erklären. Wird z.B. nur *eine* Lösung gesucht, so stellen die numerischen Werte keine Wahrscheinlichkeit dar, sondern können lediglich zur heuristischen Beurteilung der einzelnen Hypothesen verwendet werden.

Zur Angabe eines probabilistischen Benutzermodells ist stets vollständiges Wissen über die bedingten Wahrscheinlichkeiten aller möglichen Alternativen zur Durchführung eines Planes in einem Oder-Knoten notwendig. Liegt dieses nicht vor, muß eine Heuristik wie die Annahme einer uniformen Verteilung herangezogen werden.

Es werden keine Methoden vorgestellt, um die numerischen Werte durch Langzeitbeobachtungen zu gewinnen oder zu aktualisieren, falls neue Informationen dies notwendig machen.

3.2.2 Das System Wimp3

Der Nachfolger des in Abschnitt 3.1.1 beschriebenen Systems zum Verstehen kurzer Geschichten in natürlicher Sprache ist Wimp3 [Charniak und Goldman, 1991; Charniak und Goldman, 1993], das zum Auffinden von Planhypothesen und deren numerischer Bewertung einen Marker-Passer sowie dynamisch konstruierte Bayessche Netze verwendet. Das Vorgehen des Systems ist dabei wie folgt:

1. Durch einen Parser wird ein Wort der Eingabe eingelesen. Als Resultat ergeben sich Aussagen über den Text (z.B. über erwähnte Objekte und Aktionen).
2. Diese Aussagen lösen Regeln zur Konstruktion Bayesscher Netze aus. Dabei wird ein bereits bestehendes Netz um diese Aussagen repräsentierende Knoten erweitert und anschließend numerisch bewertet.
3. Der Marker-Propagierungsalgorithmus wird angestoßen. Mit seiner Hilfe werden Verbindungen zwischen den einzelnen Knoten des Netzes hergestellt, deren assoziierte Aussagen semantische Gemeinsamkeiten und Abhängigkeiten aufweisen (z.B. Verweis auf dasselbe Objekt).
4. Diese Verbindungen lösen wiederum eine Reihe von Netzaufbauregeln sowie eine Reevaluierung des entstehenden Netzes aus.

Pläne werden in Wimp3 in einer logischen Sprache erster Ordnung repräsentiert, die im wesentlichen Aussagen über

- den Typ von Aktionen und Objekten,
- Gleichheitsaussagen und
- Rollenfüller

erlaubt. Letztere sind in erster Linie bei der Beschreibung der Dekomposition von Plänen von Bedeutung, da sie ausdrücken, welche Funktion (“Rolle”) ein bestimmtes Objekt oder eine Aktion innerhalb eines Planes einnimmt. Die folgende Formel beschreibt beispielsweise den Zusammenhang zwischen einem Plan einzukaufen und der darin enthaltenen Aktion, in ein Geschäft zu gehen.

$$\begin{aligned} (\text{inst } ?\text{shop shopping-}) \rightarrow & (\text{and } (\text{inst } (\text{go-stp } ?\text{shop}) \text{ go-}) \\ & (= (\text{agent } (\text{go-stp } ?\text{shop})) \\ & \quad (\text{agent } ?\text{shop})) \\ & (= (\text{destination } (\text{go-stp } ?\text{shop})) \\ & \quad (\text{store-of } ?\text{shop}))) \end{aligned}$$

Intuitiv bedeutet eine solche Formel folgendes. Ist ?shop ein Plan vom Typ “shopping”, dann ist der Rollenfüller von go-stp (also der Teilschritt des Planes, der eine Gehen-Aktion beschreibt), vom Typ “go”. Dieser Teilschritt muß denselben Agenten wie der Gesamtplan haben. Außerdem ist das Ziel dieses Schrittes gleich dem Rollenfüller von store-of des Planes.




Abbildung 3.3: Ein assoziatives Netz in der Wissensbasis von Wimp3.

Neben einer logischen Datenbasis wird aus diesen Angaben ein assoziatives Netz erstellt. Die Knoten darin repräsentieren die Pläne und Aktionen, die über Kanten verbunden sind, die Rolleninformation (z.B. go-stp) oder Teilklassenbeziehungen (isa) enthalten. Ein Beispiel für ein solches assoziatives Netz ist in Abbildung 3.3 dargestellt.

Zur Repräsentation probabilistischer Information wird eine spezielle Klasse von Bayesschen Netzen verwendet, sogenannte PRNs (Plan Recognition Bayesian Networks).

Den Wurzelknoten eines solchen Netzes bildet die aktuelle Planhypothese in Form eines Knotens

$$(\text{inst } \langle \text{plan_instance} \rangle \langle \text{plan_type} \rangle),$$

der mit einer *a priori*- oder *Vorabwahrscheinlichkeit* bewertet ist. Ist kein expliziter Wert angegeben, so wird eine uniforme Wahrscheinlichkeitsverteilung angenommen. Der Vertrauensgrad in diese Hypothese ist dabei die Wahrscheinlichkeit dieser Aussage, daß nämlich die aktuelle Planinstanz zur Klasse “plan_type” gehört.

Unterhalb dieses Wurzelknotens befinden sich diejenigen Aussagen, die dadurch erklärt werden sollen, daß sie als Rollenfüller in einem komplexeren Plan identifiziert werden.

Wird beispielsweise ein “go”-Ereignis beobachtet, das durch die Instanzvariable go1 repräsentiert wird, so kann in obigem Beispiel die Beobachtung

$$(\text{inst go1 go-})$$

durch die beiden Aussagen

$$(\text{= (go-stp plan1) go1}) \quad \text{und} \quad (\text{inst plan1 liquor-shopping})$$

erklärt werden, mit deren Hilfe go1 als Teilschritt eines “liquor-shopping” Planes plan1 identifiziert wird.

Die entsprechenden Bayesschen Netze werden durch eine Reihe von Konstruktionsregeln beim Auftreten einer neuen Evidenz dynamisch generiert und erweitert. Zwei dieser Regeln sollen hier kurz erläutert werden (für eine detaillierte Beschreibung sei auf [Charniak und Goldman, 1993] verwiesen).

“Slot-filler”: Sind i und j zwei Instanzen der Typen t_i bzw. t_j mit den entsprechenden Knoten $a_1 = (\text{inst } i \ t_i)$ und $a_2 = (\text{inst } j \ t_j)$ im aktuellen Netz, und enthält die Wissensbasis den Eintrag, daß Instanzen vom Typ t_i für *slot* einen Rollenfüller vom Typ t_j benötigen, so wird als neuer Knoten $c = (\text{= (slot } i) \ j)$ eingeführt und mit Hilfe der Kanten $a \rightarrow c$ und $b \rightarrow c$ in das Netz integriert. Als Wahrscheinlichkeit $P(c|a, b)$ wird $P(=)/P(t_j)$ eingetragen.

Abbildung 3.4 zeigt die Verbindung zweier isolierter Evidenz- und Hypotheseknoten durch die Anwendung dieser Regel. Die bedingte Wahrscheinlichkeit nimmt hier den Wert $1/|\text{liquor} - \text{store}|$ an. Prinzipiell muß also für jeden Typ die Menge aller Instanzen bekannt sein. Dieser Wert ist die Wahrscheinlichkeit dafür, daß als “store-of” des Planes plan1 genau dasselbe Geschäft gewählt wurde, das bereits durch store1 beschrieben wird.

“Up-existential”: Sei $b = (\text{inst } j \ t_j)$ ein Knoten des aktuellen Netzes. Die Wissensbasis enthalte die Formel

$$(\text{inst } ?i \ t_i) \rightarrow (\text{inst (slot } ?i) \ t_j).$$

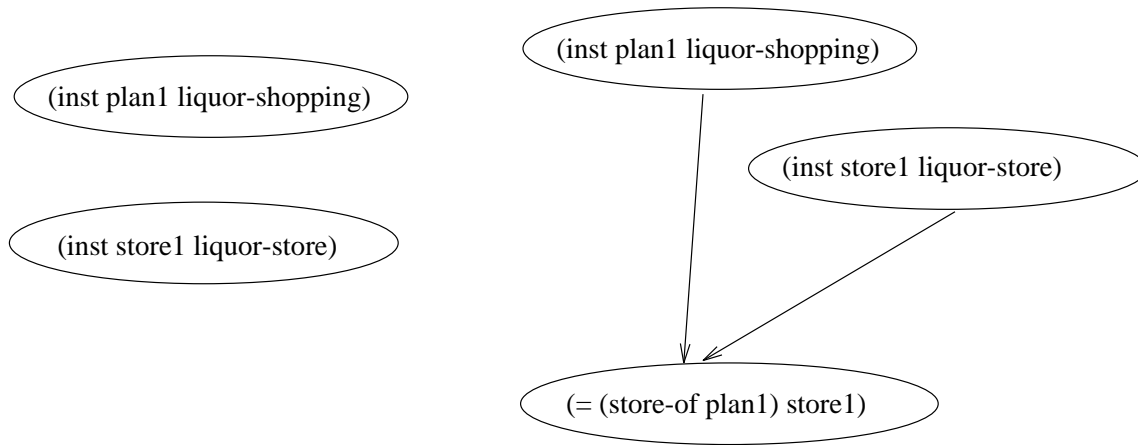


Abbildung 3.4: Konstruktion eines PRN durch Anwendung der Regel “Slot-filler.”

Dabei ist t_i ein Ereignis oder t_j ein Objekt. Dann wird das Netz erweitert um die Knoten $a = (\text{inst } i \ t_i)$ und $c = (= (\text{slot } i) \ j)$ und die Kanten $a \rightarrow c$, $b \rightarrow c$ und $a \rightarrow b$. Es ergeben sich die Wahrscheinlichkeiten $P(b|a) = 1$, $P(b|\neg a) = P(t_j) - P(t_j|a) \cdot P(a)$ und $P(c|a, b) = 1$, sonst 0. Abbildung 3.5 zeigt ein Beispiel für die Expansion eines Netzes mit dem einzelnen Knoten $(\text{inst } \text{go1 } \text{go-})$ durch einen solchen Schritt.

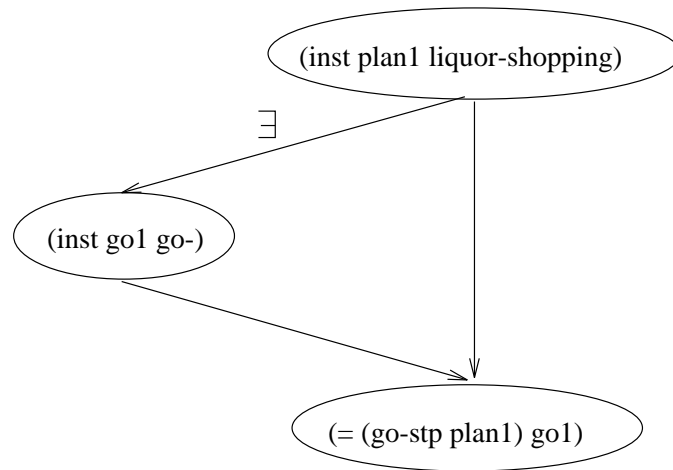


Abbildung 3.5: Expansion eines PRN durch Anwendung der Regel “Up-existential.”

Probleme bei der Anwendung solcher Regeln – insbesondere der letzten – treten immer dann auf, wenn eine Aktion Teilschritt vieler verschiedener Pläne sein kann oder Pläne rekursiv definiert sind. Im ersten Fall wird das entstehende PRN zu groß, um praktisch handhabbar zu sein, im zweiten Fall besteht das Problem der Terminierung.

Um daher die Anwendung dieser Konstruktionsregeln zu steuern, wird ein Marker-Propagierungsalgorithmus auf dem assoziativen Netz eingesetzt, dessen Kanten En-

titäten mit ihren Klassen und Rollenfüllern sowie mit ihren Sub- und Superklassen verbinden. Ausgehend von neuen Beobachtungen propagiert der Algorithmus Markierungen durch dieses Netz und konstruiert so Pfade zwischen einer Entität und einem bereits existierenden Plan oder verbindet zwei Entitäten mit einem hypothetisierten Plan. Ein Filter entfernt dabei “unnütze” Pfade. Alle verbleibenden Pfade werden zur Anwendung der Konstruktionsregeln verwendet. Das wichtigste Auswahlkriterium dieses Filters ist die Vorabwahrscheinlichkeit der einzelnen Hypothesen. Dies führt dazu, daß extrem schlecht bewertete Pläne vorerst nicht weiter betrachtet werden. Die so erhaltenen kleineren PRNs führen zu einer Verringerung der Komplexität. Planerkennung wird somit zu einem mehrstufigen Prozeß:

1. Der Parser liefert eine logische Beschreibung der Eingabe.
2. Die semantische Verarbeitung fügt Knoten zum bestehenden PRN hinzu.
3. Der Marker-Propagierungsalgorithmus berechnet lohnende Pfade im assoziativen Netz.
4. Diese feuern die Konstruktionsregeln, was zu einer Expansion und Reevaluierung des PRN mit der Neuberechnung der Wahrscheinlichkeiten führt.

Kritik:

Ein Kritikpunkt an Wimp3 ist die Annahme uniformer Wahrscheinlichkeitsverteilungen im Falle fehlender Information. Dieses Vorgehen ist bedingt durch die Basierung des Ansatzes auf der klassischen Wahrscheinlichkeitstheorie.³

Ein ähnliches Vorgehen erfordert die Kodierung einer Evidenz, die nicht spezifisch genug ist, um auf *einzelne* Hypothesen hinzudeuten. Ist eine Aktion a beispielsweise notwendiger Bestandteil einer *Menge* X von Plänen, so erlaubt die Beobachtung a ohne weitere Information lediglich den Schluß auf die Menge X der mit a kompatiblen Hypothesen. Im von Wimp3 verfolgten Ansatz mit PRNs werden jedoch immer nur *Einzelhypothesen* betrachtet, wodurch ein Teil der Information – nämlich die fehlende Präzision der Evidenz – verlorenggeht. Die gegebene Situation würde in diesem Fall so modelliert, daß die Beobachtung a jedes einzelne Element in X gleichermaßen unterstützt. Die Entscheidung, welches davon im aktuellen PRN tatsächlich auftaucht, wird in einem solchen Fall ausschließlich von der Vorabwahrscheinlichkeit der Hypothesen abhängen.

Ein weiterer Punkt bezieht sich auf die konkret verwendeten numerischen Werte selbst. Die Anwendung von Bayesschen Netzen in der Planerkennung minimiert zwar die Anzahl der benötigten bedingten Wahrscheinlichkeiten, aber in vielen Fällen ist selbst die Bestimmung (oder Abschätzung) dieser relativ wenigen Werte nahezu unmöglich. So verlangt etwa das Beispiel aus Abbildung 3.5, das in dieser Form [Charniak und Goldman, 1993, Seite 65] entnommen wurde, die Angabe der Größe

³Zu Diskussionen des Aspektes der Unvollständigkeit von Wissen sei an dieser Stelle auf die Abschnitte 2.1 und Kapitel 4 verwiesen.

$1/|\text{liquor} - \text{store}|$, d.h. die Anzahl aller Spirituosenläden muß zur Berechnung dieser Größe bekannt sein. Es ist kaum nachzuvollziehen, warum eine größere Anzahl solcher Läden die Wahrscheinlichkeit eines Einkaufsplanes verringern sollte, warum also spezifische Größen in der Domäne die Bewertung einer Planhypothese beeinflussen.

3.3 Systeme mit alternativen Unsicherheitsmodellen

In diesem Abschnitt werden zwei Ansätze zur Bewertung der Hypothesen eines Planerkennters vorgestellt, deren numerischer Formalismus sich von der klassischen Wahrscheinlichkeitstheorie unterscheidet. Dabei handelt es sich im ersten Fall um den Versuch, numerische Maße des Informationsgehalts einer natürlichsprachlichen Äußerung zur Aktualisierung von Wahrscheinlichkeiten zu verwenden. Der zweite beschriebene Ansatz baut demgegenüber auf der Dempster-Shafer Theorie auf, die zur Modellierung von Default-Schlüssen im Rahmen der Planerkennung verwendet wird.

3.3.1 Integration informationstheoretischer Maße

Wie Wimp3, so arbeitet auch das in [Raskutti und Zukerman, 1991a; Raskutti und Zukerman, 1991b] beschriebene System zur Planerkennung im Kontext der Verarbeitung natürlicher Sprache. Speziell handelt es sich hierbei um Beratungssysteme, die z.B. aus den Äußerungen des Kunden eines Reisebüros dessen zugrundeliegenden Plan extrahieren und entsprechende Dienste wie Buchen der benötigten Flüge anbieten. Der Aspekt der Unsicherheit kommt dadurch ins Spiel, daß vom Anwender oft nur partielle oder teilweise inkorrekte Information geliefert wird, was eine Quelle der Mehrdeutigkeit seiner Aussagen darstellt. Die verschiedenen möglichen Interpretationen werden probabilistisch bewertet, wobei ihr *Informationsgehalt* berücksichtigt wird.

Eine *Interpretation* einer Benutzeraussage ist eine Folge von Plänen, deren Ausführung der Benutzer vorschlägt. Ein *Plan* wird in [Raskutti und Zukerman, 1991a] definiert als eine Aktion zusammen mit einer Anzahl von Parametern, die diese Aktion definieren. Der beschriebene probabilistische Ansatz zur Hypothesenbewertung versteht sich als eine Erweiterung des in Wimp2 verwendeten Mechanismus (siehe Abschnitt 3.1.1), der auf der Annahme beruht, daß besser definierte Pläne (also Pläne, die durch die Benutzerangaben exakter spezifiziert sind) wahrscheinlicher sind als solche, die durch die Äußerung des Benutzers nur unzureichend beschrieben werden. Diese Annahme ist nur im Fall der sogenannten “intendierten Erkennung” gültig, in der der beobachtete Agent selbst Wert darauf legt, daß sein Plan erkannt wird (im Gegensatz zur “keyhole-recognition”, bei der der Agent den Planerkennungsprozeß *nicht* unterstützt).

Der Erkennungsprozeß läuft in drei Phasen ab:

1. Die Eingabe besteht aus einer logischen Repräsentation der natürlichsprachlichen Eingabe des Benutzers. In einem *direkten Inferenzprozeß* werden daraus mögliche Interpretationen generiert, wobei sowohl die Definitionen von Domänenaktionen, als auch Kohärenzbetrachtungen berücksichtigt werden. Die durch Ambiguitäten entstehenden Unsicherheiten werden quantifiziert, indem die Wahrscheinlichkeit einer Interpretation jeder neuen Äußerung, die Wahrscheinlichkeit einer Interpretation des vorausgehenden Diskurses sowie die Wahrscheinlichkeit einer Beziehung zwischen beiden berechnet werden. Mit Hilfe dieser Werte kann die Menge der möglichen Interpretationen eingeschränkt werden. Eine genauere Beschreibung der Berechnungen dieser und der beiden folgenden Phasen findet sich weiter unten.
2. Diese Interpretationen sind üblicherweise unvollständig. Die unspezifizierten Details werden durch *indirekte Inferenzen* unter Zuhilfenahme anderer Informationsquellen ausgefüllt. Diese erlauben Schlüsse unterschiedlicher Stärke, die direkt proportional zur Zuverlässigkeit der verwendeten Informationsquelle ist (z.B. Inferenzen aus Benutzeraussagen gegenüber Schlußfolgerungen aus Standardannahmen über die Domäne). In dieser Phase der Planerkennung werden diese unterschiedlichen Stufen dazu benutzt, zu verhindern, daß eine Schlußfolgerung durch eine schwächere Inferenz widerlegt wird.
3. Nach jeder dieser beiden Phasen wird jeweils der Informationsgehalt der verschiedenen Interpretationen berechnet, um zu entscheiden, ob der Inferenzprozeß fortgesetzt werden soll. Dasselbe Maß wird am Ende der Phase 2 verwendet, um die Wahrscheinlichkeit der Interpretationen mit höherem Informationsgehalt zu erhöhen. Die errechneten Werte werden zur Einschränkung des Suchraums verwendet.

Die Berechnung der Wahrscheinlichkeiten

Der aktuelle Diskurs S' bestehe aus dem vorausgehenden Diskurs S und der neuen Äußerung s . Die Menge der möglichen Interpretationen von S ist $\{I_j\}_j$, die von s $\{i_k\}_k$. Ferner sei $\{R_m\}_m$ die Menge der möglichen Relationen zwischen einer Interpretation I_j von S und einer Interpretation i_k von s . Eine solche Relation ist entweder *elaboration*, *introduction* oder *correction* zusammen mit den involvierten Objekten, auf die jeweils verwiesen wird. D bezeichne das Domänenwissen des Zuhörers (Beobachters). Die Wahrscheinlichkeit, daß der Sprecher eine Interpretation I_{jkm} , bestehend aus I_j , i_k und R_m , für S' intendierte, ist $P(I_{jkm}|S', D)$. Da das Domänenwissen unverändert bleibt, wird es im folgenden nicht mehr explizit aufgeführt:

$$P(I_{jkm}|S') = P(I_j, i_k, R_m|S, s) = \frac{P(I_j, i_k, R_m, S, s)}{P(S, s)}. \quad (3.1)$$

Der Zähler kann auch geschrieben werden als

$$P(I_j, i_k, R_m | S, s) = \underbrace{P(S|s, i_k, I_j, R_m)}_{(1)} \cdot \underbrace{P(s|i_k, I_j, R_m)}_{(2)} \cdot \underbrace{P(R_m|i_k, I_j)}_{(3)} \cdot \underbrace{P(I_j|i_k)}_{(4)} \cdot \underbrace{P(i_k)}_{(5)}.$$

Dabei gilt für die einzelnen Faktoren:

- (1) $P(S|s, i_k, I_j, R_m) = P(S|I_j)$, da S bedingt unabhängig von s , i_k und R_m ist, gegeben I_j . Dies ist die Wahrscheinlichkeit, daß der Sprecher S äußert, wenn er die Interpretation I_j intendiert.
- (2) $P(s|i_k, I_j, R_m) = P(s|i_k)$ ist das entsprechende Maß für s und seine Interpretation i_k .
- (4) $P(I_j|i_k) = P(I_j)$, da I_j die Aussagen *vor* s interpretiert und somit von i_k unabhängig ist.

Somit ergibt sich für (3.1):

$$P(I_{jkm} | S') = \frac{P(S|I_j) P(s|i_k) P(R_m|i_k, I_j) P(I_j) P(i_k)}{P(S, s)} \quad (3.2)$$

Die Abschätzung der Werte $P(S)$, $P(s)$ und $P(S, s)$ für die Wahrscheinlichkeiten des Auftretens der verschiedenen Aussagen ist i.a. sehr schwierig. Da sie aber unabhängig von den Wahrscheinlichkeiten der Interpretationen sind, kann (3.2) nach Einführung einer normalisierenden Konstanten $\alpha = \frac{P(S)P(s)}{P(S, s)}$ umgeschrieben werden zu

$$P(I_{jkm} | S') = \alpha P(I_j | S) P(i_k | s) P(R_m | i_k, I_j), \quad (3.3)$$

wodurch ein Vergleich der Wahrscheinlichkeiten von Interpretationen möglich wird.

Die Berechnung der numerischen Werte für die Faktoren in (3.3) beruhen auf einer Reihe von Heuristiken wie der Annahme uniformer Wahrscheinlichkeitsverteilungen bei fehlender Information oder Präferenzen, die sich aus Kohärenzbetrachtungen des Diskurses ergeben (z.B. Bevorzugung von Verweisen auf jüngere Äußerungen gegenüber Referenzen auf ältere). Diese domänenunabhängigen Überlegungen können durch anwendungsspezifisches Wissen ergänzt werden. Nach der Normalisierung aller Wahrscheinlichkeiten werden alle Interpretationen mit

$$\frac{P(I)}{P_{max}} < x_0$$

verworfen, wobei P_{max} der größte von einer Interpretation erreichte Wert und $x_0 \in [0, 1]$ ein Schwellwert ist.

Der *Informationsgehalt* eines Parameters innerhalb eines Planes einer Interpretation wird aus der numerischen Gewichtung des Inferenzprozesses berechnet, aus dem

er abgeleitet wurde. Dabei werden direkte Inferenzen aus Benutzeraussagen mit 1, alle anderen wie Schlüsse aus dem Domänenwissen, Domänenannahmen, dem Benutzermodell sowie Commonsense-Schlüsse absteigend bewertet. Jeder Parameter p eines Planes wird dazu mit dem Informationstyp markiert, der zu seiner Herleitung führte, ohne jedoch die Markierungen der zu diesem Schluß erforderlichen Parameter p_1, \dots, p_n zu berücksichtigen. Wie in [Carberry, 1990a] (siehe auch Abschnitt 3.3.2) werden Unsicherheiten also *nicht* propagiert. Die Markierung von p – die Stärke der Inferenzregel – repräsentiert somit die bedingte Wahrscheinlichkeit $P(p|p_1, \dots, p_n)$.

Während des indirekten Inferenzprozesses, in dem die verbliebenen Lücken in den Interpretationen geschlossen werden, wird für jeden Parameter nur die *stärkste* mögliche Ableitung eines Wertes betrachtet, um so den Suchraum einzuschränken.

Der Informationsgehalt einer Interpretation kann nun als Summe des Informationsgehalts aller in ihr enthaltenen Pläne berechnet werden, die sich wiederum aus den entsprechenden Werten für ihre Parameter ergeben. Für einen Parameter p ist

$$IC(p) = \log_2 \frac{S(p)}{N(p)},$$

wobei $N(p)$ die Anzahl der möglichen Werte für p und $S(p)$ die mit p assoziierte Inferenzstärke ist. Für eine Interpretation I mit Plänen $P_i, i = 1, \dots, k$ mit Parametern $p_{ij}, j = 1, \dots, l_i$, ergibt sich somit

$$IC(I) = \sum_{i=1}^k \sum_{j=1}^{l_i} \log_2 \frac{S(p_{ij})}{N(p_{ij})}.$$

Gilt $IC(I_0) = 0$, für eine Interpretation I_0 , so ist diese eindeutig identifiziert. Kann der Informationsgehalt einer Interpretation nicht weiter aus der gegebenen Evidenz erhöht werden, wird der Inferenzprozeß gestoppt.

Mit Hilfe des IC -Wertes kann nun die Wahrscheinlichkeit der Interpretationen aktualisiert werden:

$$P_{neu}(I) = P(I) \left(1 - \frac{IC(I)}{ICNORM} \right),$$

wobei $ICNORM$ der in der Domäne minimal mögliche IC -Wert ist. Diese Berechnung auf der Basis des Informationsgehalts ist nur in Anwendungen gültig, in denen der Sprecher aktiv versucht, sein Ziel mitzuteilen.

Kritik:

Neben der Einschränkung auf Anwendungen mit intendierter Erkennung sind folgende Punkte zu erwähnen:

1. Das Verhalten des Systems ist sehr stark vom Entwurf der verwendeten Heuristiken und hier speziell der Wahl der numerischen Konstanten x_0 und $ICNORM$ abhängig, wodurch die Vorhersagbarkeit der erzielten Ergebnisse und somit die Rechtfertigung der getroffenen Entscheidungen erschwert wird.

2. Da für jeden Parameter immer nur die stärkste Inferenz betrachtet wird, kann es vorkommen, daß der bei einer gegebenen Evidenz maximal mögliche Informationsgehalt nicht erreicht wird. Seien z.B. zwei Parameter p_1, p_2 gegeben. p_2 werde mittels p_1 abgeleitet. Sei nun $p_1 = x_1$ mit einer Inferenz der Stärke v_1 abgeleitet. Daraus ergebe sich mit Stärke v_2 der Wert $p_2 = y_1$. Ferner sei die Ableitung $p_1 = x_2$ mit Stärke $v'_1 < v_1$ möglich (dieser Schritt wird jedoch niemals ausgeführt). Daraus ergebe sich mit Stärke $v'_2 > v_2$ der Schluß $p_2 = y_2$. Ist nun $v_1 + v_2 < v'_1 + v'_2$, so wird der Informationsgehalt der entsprechenden Interpretation nicht maximal, d.h. es wird Information verschenkt, wodurch jedoch der Suchraum eingeschränkt wird.
3. Die Tatsache, daß die Stärke der Ableitung eines Parameterwertes nicht propagiert wird, stellt einen Informationsverlust dar, der zwar psychologisch gerechtfertigt wird, jedoch große Auswirkungen auf die numerischen Berechnungen hat. Vergleiche dazu auch die Diskussion des Ansatzes von Carberry in Abschnitt 3.3.2.

3.3.2 Modellierung von Default-Schlüssen mit Dempster-Shafer Theorie

Das von Carberry in [1990a; 1990b] vorgestellte “Prozeßmodell der Planerkennung” findet seine Anwendung in der Verarbeitung natürlichsprachlicher Dialoge. Die Motivation für diese Arbeit war der Versuch, ein Modell der Planerkennung zu entwickeln, das angesichts mehrerer möglicher Hypothesen *nicht* darauf abzielt, die mathematisch beste Repräsentation des Benutzerplans zu erreichen und die unter probabilistischen Gesichtspunkten optimale Entscheidung zu treffen. Vielmehr geht es hier darum, *vernünftige* Schlüsse zu ziehen, die eine Rechtfertigung der getroffenen Entscheidungen gegenüber dem Benutzer des Systems erlauben.

So wird beispielsweise der Wimp2-Ansatz wegen seiner “komplizierten Berechnungen” kritisiert, die zwar mathematisch korrekt, einem Laien aber nicht vermittelbar sind. Darüberhinaus werden diese Berechnungen als zu aufwendig betrachtet.

Vielmehr sollen hier Aspekte menschlichen Schließens in die Planerkennung integriert werden, die es erlauben,

- vernünftige Hypothesen aufgrund von Default-Schlüssen aufzustellen und nicht gerechtfertigte Entscheidungen zu verschieben, bis zusätzliche Information verfügbar ist,
- diese Hypothesen gemäß ihrer Plausibilität zu ordnen und
- gegebenenfalls Schlüsse zu revidieren.

Die Arbeitsweise des Planerkennungsprozesses besteht darin, ein sogenanntes *Kontextmodell* inkrementell aufzubauen und zu expandieren. Dabei handelt es sich um

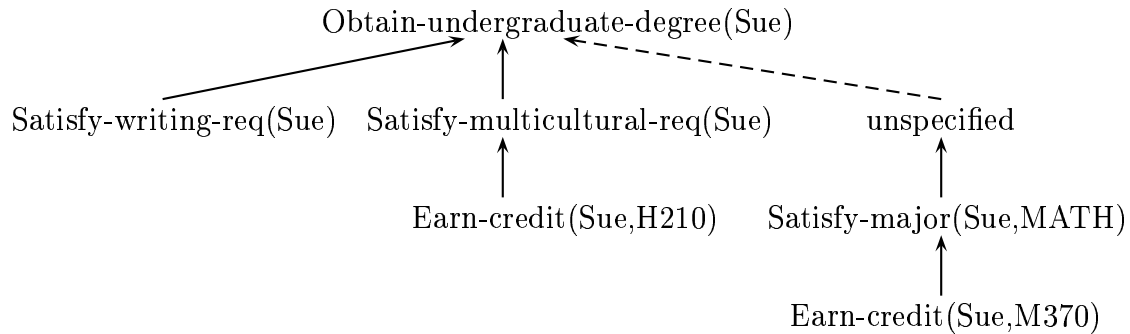


Abbildung 3.6: Beispiel eines Kontextmodells.

einen Baum, dessen Knoten Aktionen bezeichnen, von denen das System annimmt, daß der Benutzer sie ausführen will. Zwischen diesen Knoten gibt es zwei Arten von Kanten:

1. Eine *direkte Kante* von A_i nach A_j bedeutet, daß A_i ein Teil der operationalen Dekomposition von A_j ist.
2. Eine *indirekte Kante* von A_i nach A_j deutet darauf hin, daß A_i Teil einer Expansion von A_j ist, d.h. daß es mehrere Dekompositionen für A_j gibt, die A_i enthalten. Die gegebene Information reicht jedoch nicht aus, sich bereits für eine Alternative zu entscheiden.

Beispiel 3.3.1 Die Abbildung 3.6 aus [Carberry, 1990a] zeigt ein solches Kontextmodell, wobei der gestrichelte Pfeil eine indirekte, alle anderen Pfeile direkte Kanten darstellen. In der Beispieldomäne geht es um Beratung von Studenten zur Erfüllung bestimmter Anforderungen im Rahmen ihres Studiums. Die direkten Kanten verbinden Subaktionen mit übergeordneten Plänen. Die indirekte Kante weist darauf hin, daß es mehrere Möglichkeiten gibt, den Toplevel-Plan *Obtain-undergraduate-degree* auszuführen und dabei die Aktion *Satisfy-major(.,MATH)* zu integrieren.⁴ Die vorhandene Information reichte hier nicht aus, sich für eine der Alternativen zu entscheiden. Auf dieses Beispiel wird nochmals bei der Diskussion der verwendeten Heuristiken eingegangen.

Mit jeder neuen Äußerung muß das Kontextmodell angepaßt und expandiert werden, um die aktuelle Hypothese des Benutzerplans zu repräsentieren. Dazu werden eine Reihe von Heuristiken verwendet, die hier nicht näher betrachtet werden sollen. Vielmehr werden der Vorgang der Expansion des Kontextmodells und die Integration des numerischen Formalismus zur Bewertung von Hypothesen näher untersucht, dessen Grundlage die Dempster-Shafer Theorie bildet. Diese Wahl wird damit begründet,

⁴Diese Notation soll eine beliebige Bindung des ersten Arguments von *Satisfy-major* repräsentieren.

Definition 3.3.2 (Ableitbarkeit einer Hypothese)

Seien E eine Menge von Aktionen mit Präferenzregel P_E gemäß Definition 3.3.1, $\epsilon_{pl}, \epsilon_d \in [0, 1]$. Dann ist

$$Infer(E) := \begin{cases} A_g, & \text{falls } A_g \in \Theta \text{ der einzige Plan ist, dessen} \\ & \text{Dekomposition alle in } E \text{ auftretenden Aktionen beinhaltet} \\ A_g, & \text{falls } (A_g \in \Theta) \wedge (PF_E(A_g) > \epsilon_{pl}) \wedge \\ & [\neg \exists A_k. (PF_E(A_k) > PF_E(A_g)) \vee (PF_E(A_g) - PF_E(A_k) < \epsilon_d)] \\ \emptyset, & \text{sonst} \end{cases}$$

Ist $Infer(E) = A_g$, so heißt A_g *aus E ableitbar*. Die Größen ϵ_{pl} und ϵ_d heißen *Plausibilitätsschwelle* bzw. *Differenzschwelle*.

Um eine Hypothese A_g aus einer Evidenz ableiten zu können, ist es also notwendig,

- daß A_g entweder der einzige Kandidat zur Erklärung von E ist **oder**
- daß die Plausibilität von A_g einen gewissen Mindestwert ϵ_{pl} überschreitet und alle anderen Hypothesen A_k mindestens um ϵ_d schlechter bewertet sind.

Mit Hilfe der Schwellwerte ϵ_{pl} und ϵ_d lassen sich je nach Anwendung “vorsichtiger” oder “spekulativer” Inferenzen modellieren.

Um nun ein Kontextmodell aufzubauen, erhält das System als initiale Eingabe eine Menge von Plänen mit ihren Dekompositionen und die mit den verschiedenen Aktionen assoziierten Basiswahrscheinlichkeiten, aus denen dynamisch Präferenzregeln berechnet werden. Dabei können Pläne auch in nicht-elementare Teilpläne zerlegt werden, die ihrerseits wieder Dekompositionen besitzen, so daß eine beliebig abstrakte Repräsentation eines Planes möglich ist. Verschiedene Heuristiken identifizieren nun Aktionen, die eine bestimmte Äußerung des Benutzers motivieren könnten und fokussieren auf die kohärenteste Beziehung zwischen der mit der aktuellen Äußerung assoziierten Aktion und dem aktuellen Kontextmodell als Repräsentation der Hypothese des Systems bzgl. des Planes des Benutzers.

Die folgenden Regeln integrieren die oben beschriebenen Default-Schlüsse in den Prozeß der Expansion des Kontextmodells.

D1: Die mit einer Äußerung assoziierte Aktion A_{new} sei Teil eines Planes zur Ausführung von A_c im Kontextmodell. Gleichzeitig gebe es mehrere Dekompositionen für A_c , die A_{new} beinhalten. Wenn $Infer(\{A_{new}\}) = A_j$ ist und A_j Teil einer Dekomposition für A_c , so füge einen Knoten A_j zum Kontextmodell hinzu mit einer direkten Kante von A_{new} zu A_j und wiederhole **D1** mit A_j anstelle von A_{new} . Ansonsten füge einen uninstanziierten Knoten X mit einer direkten Kante $A_{new} \rightarrow X$ und einer indirekten Kante $X \rightarrow A_c$ zum Kontextmodell.

Diese Regel erlaubt also sowohl die Verwendung von Default-Schlüssen zur Einführung neuer Knoten, als auch die Verschiebung einer solchen Entscheidung, falls die verfügbare Information unzureichend ist. Ein kurzes Beispiel soll die Arbeitsweise dieser Regel veranschaulichen.

Seien dazu $\epsilon_{pl} = 0.9$ und $\epsilon_d = 0.7$. Sue stellt eine Anfrage bzgl. einer schriftlichen Arbeit (“writing project”) und einem multikulturellen Kurs (“multicultural course”). Das System schließt daraus, daß Sue einen Studienabschluß (“undergraduate degree”) machen möchte. Als nächstes fragt sie nach dem Kurs M370 über Wahrscheinlichkeitstheorie. Die Heuristiken zur Identifizierung des Benutzerplanes liefern die Domänenaktion “Earn-credit(Sue,M370)” als mögliche Motivation für Sues Anfrage. Das Systemwissen über die Anwendungsdomäne beinhaltet einen Plan zum Erlangen des Abschlusses, der M370 beinhaltet. Folglich wird vom System abgeleitet, daß Sue diesen Kurs als Teil dieses Planes belegen will. Es gibt jedoch mehrere Möglichkeiten, M370 in einen solchen Plan zu integrieren, nämlich als Erfüllung einer Prüfungsanforderung in Mathematik, Informatik oder als Wahlfach. Durch Anwendung der Präferenzregel

if { Earn-credit(_user, M370) }	p-then Satisfy-major(_user,MATH),	1.00
	Satisfy-major(_user,CS),	0.15
	Other,	0.03

ergibt sich $\text{Infer}(\{\alpha\}) = \text{Satisfy-major}(\text{Sue}, \text{MATH})$. Als Default-Schluß ergibt sich durch Regel D1, daß Sue durch M370 die Mathematik-Anforderungen für ihren Abschluß erfüllen will.

D1 schreibt nun die rekursive Anwendung dieser Regel auf diesen neuen Eintrag im Kontextmodell vor. Da sich aus der Präferenzregel

if { Satisfy-major(_user,MATH) }	p-then Earn-degree(_user,BA),	1.00
	Earn-degree(_user,BS),	0.85
	Other,	0.10

keine weiteren Schlußfolgerungen ziehen lassen wegen

$$\text{Infer}(\{\text{Satisfy-major}(\text{Sue}, \text{MATH})\}) = \emptyset,$$

bleibt unklar, ob das Ziel ein Abschluß als BS oder BA ist. Diese Entscheidung wird solange verschoben, bis zusätzliche Evidenz verfügbar ist. Das resultierende Kontextmodell ist in Abbildung 3.6 dargestellt.

D2: Seien A_1, \dots, A_k und eine neue Aktion A_{new} Teile eines gemeinsamen, noch unbestimmten Planes X im Kontextmodell. Dann füge A_{new} hinzu mit einer direkten Kante $A_{new} \rightarrow X$ und berechne eine neue Präferenzregel für $\{A_1, \dots, A_k, A_{new}\}$, indem die jeweiligen Basiswahrscheinlichkeiten mit Dempsters Regel kombiniert werden. Falls $\text{Infer}(\{A_1, \dots, A_k, A_{new}\}) = Y \neq \emptyset$, so instantiiere X mit Y .

Diese Regel beschreibt die Akkumulation von Information bis zu dem Punkt, an dem eine Entscheidung möglich ist. Dabei erlaubt die Assoziativität von Dempsters Regel die inkrementelle Ergänzung der entsprechenden Präferenzregel, sobald eine neue Aktion auftritt.

D3: Wenn A_r der Wurzelknoten des Kontextmodells ist und $Infer(\{A_r\}) = X \neq \emptyset$, dann füge X mit einer direkten Kante $A_r \rightarrow X$ hinzu. Ansonsten füge einen uninstanziierten Knoten Y mit einer indirekten Kante $A_r \rightarrow Y$ zum Kontextmodell hinzu, um anzudeuten, daß der Benutzer vermutlich beabsichtigt, A_r auszuführen, um eine andere, noch unbekannte Aktion durchzuführen.

Mit dieser Regel können für eine im Kontextmodell auftretende Aktion Erklärungen auf einer höheren Ebene mittels Default-Schlüssen gefunden werden.

D4: Sei A_d durch einen Default-Schluß zum Kontextmodell hinzugefügt worden. Die aktuelle Äußerung bestätigt A_d explizit oder ist mit einer Aktion gleichgesetzt, die nur Teil eines Planes für A_d sein kann. Es gibt also keine abstrakteren Pläne, die die aktuelle Äußerung erklären. Dann markiere A_d als durch diese neue Evidenz bestätigt.

D5: Sei A_d wie oben. Die neue Aktion A_{new} ist Bestandteil eines Planes für A_d . Zusätzlich sei A_{new} "repräsentativ" für A_d , d.h. ein "typischer" Bestandteil eines Planes für A_d . Dann markiere A_d als durch A_{new} bestätigt.

In diesen beiden Regeln werden Default-Schlüsse nachträglich durch eine zusätzliche Information bestätigt. Handelt es sich dabei in **D4** um sicheres Wissen, so wird in **D5** das psychologisch verankerte Kriterium der "Repräsentativität" angewandt, um einen solchen Schluß zu sanktionieren.

Entsprechend existieren Regeln, die das bestehende Kontextmodell im Falle von Widersprüchen revidieren, indem Knoten entfernt und wiederum dynamisch veränderte Präferenzregeln angewandt werden.

Kritik:

Neben den in [Charniak und Goldman, 1993] angesprochenen Kritikpunkten, die die unzureichende Begründung der Entscheidung für Dempster-Shafer Theorie betreffen, weist der hier vorgestellte Ansatz weitere Defizite u.a. auch in der *Anwendung* dieses Formalismus auf:

1. Zur Berechnung von Präferenzregeln wird als Eingabe eine Menge von "Evidenzen" mit assoziierten Basiswahrscheinlichkeiten benötigt. Letztere erlauben die direkte Bewertung von Hypothesenmengen, ohne Werte für alle Einzelhypothesen angeben zu müssen. Dieser Vorteil der Dempster-Shafer Theorie wird jedoch durch die Umwandlung der Basiswahrscheinlichkeiten in Präferenzregeln

mit Plausibilitätsfaktoren aufgegeben, da als Konklusion hier nur *einzelne* Pläne auftreten dürfen. Die Folge ist, daß beim Aufbau des Kontextmodells entweder eine eindeutige Entscheidung zugunsten einer Hypothese gefällt oder diese Entscheidung solange aufgeschoben wird, bis die gegebene Information eine solche Festlegung erlaubt. Der in einem solchen Fall eingeführte uninstantiierte Knoten schränkt den Suchraum der plausiblen Hypothesen prinzipiell nicht ein.

Ließe man als Konklusion von Präferenzregeln auch Hypothesen*mengen* zu, wäre es möglich, diese in einen Knoten einzutragen und somit den Raum der möglichen Hypothesen zumindest soweit einzuschränken, wie die vorhandene Information dies zuläßt (siehe auch 4.).

Beim Entwurf dieses Systems wurde großer Wert auf kognitiv adäquates Verhalten und mögliche Rechtfertigungen von Systemschlüssen gelegt. Die Eingabe von Basiswahrscheinlichkeiten als initiales Maß ist jedoch eine nicht-triviale Aufgabe, die gerade für Benutzer ohne Kenntnisse über Dempster-Shafer Theorie nur sehr schwer zu bewältigen ist (etwa wenn $m_E(\{A_1, A_2\}) < m_E(\{A_1\})$).

2. Die nichtmonotone Inferenzprozedur *Infer* wird nur intuitiv begründet (wie prinzipiell alle Berechnungen). Die beiden Parameter ϵ_{pl} und ϵ_d können das Ableitbarkeitsverhalten extrem beeinflussen, so daß die gezogenen Schlüsse nur sehr schwer gerechtfertigt werden können.
3. Das Ergebnis von *Infer* ist lediglich eine Hypothese. Der mit ihr assoziierte Plausibilitätsfaktor wird *nicht* weiterverwendet, um etwa eine Vorabbewertung der Knoten im Kontextmodell für die nachfolgenden Beobachtungsschritte zu berechnen. Die numerischen Werte dienen also lediglich der lokalen Entscheidungsfindung. Sie werden nicht weiterpropagiert, um z.B. eine Hypothese zu verwerfen, deren akkumulierte Plausibilität unter einen gewissen Schwellwert sinkt.
4. Das Problem der Fokussierung auf einen einzigen Kontext stellt sich hier in ähnlicher Form wie bei den TMS-basierten Systemen (vgl. die Diskussion im Zusammenhang mit Wimp2 in Abschnitt 3.1.1), wenn auch in abgeschwächter Form. Die uninstantiierten Knoten lassen zwar noch alle Möglichkeiten zur Expansion offen, alle anderen Knoten beinhalten jedoch eine eindeutige Entscheidung und müssen daher im Falle eines Widerspruchs – wenn also die aktuelle Hypothese widerlegt wird – wieder entfernt und durch Alternativen ersetzt werden.

3.4 Zusammenfassung der Ergebnisse

Dieser Abschnitt faßt nochmals kurz die Ergebnisse der vorangehenden Diskussionen verschiedener Systeme zusammen und vergleicht diese bzgl. folgender Kategorien:

- Ist das System in der Lage, *unsichere Evidenzen* zu verarbeiten? Dies ist dann der Fall, wenn als Eingabe nicht notwendigerweise eine eindeutige Beobachtung erwartet wird, sondern beispielsweise die Angabe einer Wahrscheinlichkeitsverteilung über den möglichen Beobachtungen ausreicht.
- Kann das System die *Aussagen mehrerer unabhängiger Beobachter* gleichzeitig verarbeiten?
- Wie geht das System mit *unvollständiger Information* um? Ein positiver Eintrag (\checkmark) in dieser Kategorie bedeutet, daß das partielle Fehlen von Daten die Berechnungen des Systems nicht behindert. Ein negativer Eintrag (—) hingegen deutet darauf hin, daß auf jeden Fall vollständige Information vorhanden sein muß. Hier wie auch in anderen Fällen existieren gewisse Zwischenstufen, die an der entsprechenden Stelle erläutert werden.
- Besitzt der Ansatz eine *formale Basis*?
- Wird eine *Hypothesenbewertung* berechnet, und erlaubt diese die Ableitung einer *Reihenfolge* unter konkurrierenden Planhypothesen?
- Wird *agentenspezifische Information* – in Form eines Benutzermodells – verwendet?
- Wird dieses Benutzermodell aktualisiert, so daß sich das System an das Verhalten des Benutzers *adaptiert*?

In Tabelle 3.1 werden die Ergebnisse der vorangehenden Abschnitte nochmals kurz zusammengefaßt. Dabei werden folgende Abkürzungen verwendet.

Cal steht für den in Abschnitt 3.2.1 diskutierten Ansatz von Calistri-Yeh.

IT repräsentiert den informationstheoretischen Ansatz von Raskutti und Zukerman (siehe Abschnitt 3.3.1).

Defaults steht für Carberrys Modellierung von Default-Schlüssen mittels Dempster-Shafer Theorie (siehe Abschnitt 3.3.2).

DST schließlich markiert die Spalte für den in der vorliegenden Arbeit vorgestellten Ansatz.

Erläuterungen zu Tabelle 3.1

\checkmark ¹ Die Bewertungen der Alternativen an einem Oder-Knoten müssen explizit vom Benutzer gesetzt werden.

\checkmark ² Es wird eine uniforme Verteilung der Wahrscheinlichkeitswerte angenommen.

	Wimp2	NP	IPS	Calistri	Wimp3	IT	Defaults	DST
unsichere Evidenz	—	✓	✓	—	—	—	—	✓
mehrere Beobachter	—	—	✓	—	—	—	—	✓
unvollst. Information	✓ ^{1,2}	—	✓	✓ ²	✓ ²	—	✓	✓
formale Basis	✓	—	—	✓	✓	✓ ³	—	✓
Hypothesenbewertung	✓	—	✓	✓	✓ ⁴	✓ ⁵	✓ ⁵	✓
agentenspez. Information	—	—	—	✓ ⁶	—	—	—	✓
Adaptivität	—	—	—	—	—	—	—	✓

Tabelle 3.1: Vergleich der in diesem Kapitel vorgestellten Ansätze.

- ✓³ Der Ansatz basiert auf der Wahrscheinlichkeitstheorie, jedoch ist die Verknüpfung mit informationstheoretischen Maßen nicht formal gerechtfertigt.
- ✓⁴ Bei der Markerpropagierung werden vielversprechende Hypothesen identifiziert und vorerst nur diese weiterverfolgt.
- ✓⁵ Die berechnete Hypothesenbewertung wird nur zur lokalen Entscheidungsfindung verwendet, jedoch nicht weiterpropagiert.
- ✓⁶ Calistri-Yeh sieht in der Repräsentation von Benutzerpräferenzen eine mögliche Interpretation der verwendeten bedingten Wahrscheinlichkeiten, macht dies jedoch nicht zu einem expliziten Punkt seiner Untersuchungen (“All we need to be able to do is capture the fact that certain people may be more likely than others to choose a particular plan.” [Calistri-Yeh, 1991]).

Zusammenfassend läßt sich festhalten, daß keiner der untersuchten Ansätze *alle* in Abschnitt 1.2 aufgestellten Anforderungen an ein Planerkennungssystem erfüllt. Insbesondere ist anzumerken, daß lediglich bei Calistri-Yeh [1991] die Möglichkeit der Interpretation der verwendeten numerischen Werte als *probabilistisches Benutzermodell*

erwähnt wird. Es werden jedoch keine Methoden zur Akquisition und Aktualisierung der benötigten Informationen vorgestellt.

Ein weiteres Defizit der meisten Ansätze ist die Tatsache, daß unsichere Evidenzen nicht verarbeitet werden können. Dies ist jedoch gerade in Realweltszenarien notwendig, in denen beispielsweise die Ausgaben optischer oder akustischer Sensoren ausgewertet werden müssen.

Auch die formale Rechtfertigung der Berechnungen, die für eine eindeutige Interpretation der erzielten Ergebnisse und eine Rechtfertigung der darauf basierenden Entscheidungen durch das System von grundlegender Bedeutung ist, wird in vielen Fällen vernachlässigt. Dies trifft auch auf Ansätze wie IT (siehe Abschnitt 3.3.1) zu, die sich zwar im Rahmen einer wohlfundierten Theorie bewegen, diese jedoch um zusätzliche Operationen erweitern, ohne die sich daraus ergebenden Konsequenzen formal zu untersuchen.

Neben den Beiträgen zur

- Erweiterung einer modallogischen Theorie des evidenzbasierten Schließens um ein Sprachkonstrukt zur Repräsentation von Expertenregeln in Abschnitt 4.2 und
- der semantischen Fundierung eines regelbasierten Systems mit Hilfe dieser Theorie in Abschnitt 5.3

ist das Ziel der vorliegenden Arbeit die Vorstellung eines Ansatzes zur Planerkennung, das die in Tabelle 3.1 angegebenen Charakteristika aufweist und somit die in Abschnitt 1.2 aufgestellten Anforderungen erfüllt. Dieser Ansatz wird Inhalt von Kapitel 6 sein.

Kapitel 4

Eine modallogische Fundierung des evidenzbasierten Schließens

Es besteht eine formale Verwandtschaft zwischen den Belief- und Plausibilitätsfunktionen der Dempster-Shafer Theorie und unteren und oberen Wahrscheinlichkeiten in dem Sinne, daß diese jeweils die gleichen mathematischen Eigenschaften besitzen. Die intendierte Semantik der induzierten Vertrauensintervalle einerseits und der Wahrscheinlichkeitsintervalle andererseits weist jedoch große Unterschiede auf. So stehen die numerischen Werte innerhalb der Dempster-Shafer Theorie für den Grad des Vertrauens, der einer Aussage aufgrund gewisser Informationen (Evidenzen) zugeordnet werden kann. Im Gegensatz dazu sind die Wahrscheinlichkeitsschranken kompakte Repräsentationen einer Klasse von mit einer Menge von Randbedingungen kompatiblen Wahrscheinlichkeitsfunktionen, die etwa durch eine probabilistisch unterspezifizierte Situation gegeben sind.

Die in diesem Kapitel vorgestellte Theorie des evidenzbasierten Schließens zielt auf eine Kombination beider Aspekte in einem einheitlichen Formalismus. Die eine Evidenz betreffenden Aussagen werden in einer epistemischen Modallogik formuliert, wobei dem Charakter einer Evidenz als grundlegendem Informationsträger insoweit Rechnung getragen wird, als solche Evidenzen – etwa die Ergebnisse eines Experiments oder einer Beobachtung – nicht auf der gleichen Ebene wie die die Welt beschreibenden Fakten behandelt werden. Vielmehr werden Evidenzen als Bestandteile des Wissens eines beobachtenden Agenten betrachtet, wodurch eine große Nähe zum Konzept der Evidenz in der Dempster-Shafer Theorie erreicht wird.

Die sich ergebenden Wahrscheinlichkeiten der entsprechenden Formeln auf einer Algebra der möglichen Welten der zugrundeliegenden Logik können mit Belief- und Plausibilitätsfunktionen in Übereinstimmung gebracht werden.

Als Seiteneffekt dieser logischen und probabilistischen Untersuchung von Evidenz ergibt sich die bereits angesprochene formale Identität der Dempster-Shafer Funktionen und unteren und oberen Wahrscheinlichkeiten der die tatsächliche Welt beschreibenden Formeln. Damit erhält man eine Charakterisierung des aus einer Evidenz gewonnenen Wissens als bestmögliche Approximation der aktuellen Situation

bei einer bestimmten Information. Im gleichen Rahmen wird Dempsters Regel als die Kombination des Wissens zweier sich gegenseitig vertrauender Agenten begründet.

Die wesentliche Leistung dieser von Ruspini in [1986], [1987] und [1992] entwickelten Theorie besteht somit darin, die von der Mehrheit der Vertreter der Dempster-Shafer Theorie abgelehnte Gleichsetzung von Belief-Funktionen mit Wahrscheinlichkeitsschranken in ein probabilistisches Gesamtkonzept einzubetten, das mit der intendierten Semantik des Begriffes “Evidenz” kompatibel ist, und in dem diese formale Identität *nicht* als wesentliches Merkmal zur Charakterisierung der Belief-Funktionen verwendet wird. Vielmehr wird lediglich aufgezeigt, in welchem Sinne diese Übereinstimmung im Rahmen der vorgestellten Theorie auftritt. Weiterhin untermauert diese Theorie die Tatsache, daß die oft abgelehnte Dempster-Shafer Theorie den geeigneten Formalismus zur Behandlung von Evidenz darstellt:

“[This approach] validates the mathematical theory of evidence of Dempster and Shafer as the proper formalism for the study of evidential problems.” [Ruspini, 1986, S. 2]

Der Rest dieses Kapitels teilt sich in zwei große Abschnitte. Im ersten werden die grundlegenden Konzepte der Theorie des evidenzbasierten Schließens vorgestellt. Diese modallogische Charakterisierung der Dempster-Shafer Theorie wird dann im zweiten Teil um das Sprachkonstrukt der Konditionale erweitert. Konzentrierte sich Ruspinis Ansatz auf die “klassische” Formulierung der Dempster-Shafer Theorie im Sinne von [Dempster, 1967] und [Shafer, 1976], so bietet die hier neu eingeführte Erweiterung zusätzlich die Möglichkeit, regelbasierte Systeme mit darüber hinausgehenden Operationen in dieser Theorie zu beschreiben und ihnen somit eine formale Semantik zu verleihen.

4.1 Die Grundlagen der Theorie des evidenzbasierten Schließens

In diesem Abschnitt wird die Theorie des *evidenzbasierten Schließens* (*evidential reasoning*) vorgestellt. Sie geht zurück auf die Arbeiten [Ruspini, 1986; Ruspini, 1987] und diente unter anderem in [Ruspini *et al.*, 1992] zur Fundierung der Antwort auf eine Reihe von Kritikpunkten, die gegen Dempster-Shafer Theorie vorgebracht wurden. Zunächst soll dabei die grundlegende Idee dieser Theorie betrachtet werden, bevor auf die technischen Details eingegangen wird.

Grundlage für die Theorie des evidenzbasierten Schließens ist eine Logik des Wissens auf der Basis der Modallogik S5. In dieser Sprache wird der Zustand eines nicht allwissenden Agenten modelliert. Bei der Betrachtung der Semantik dieser Logik wird deutlich, daß gewisse Wahrscheinlichkeiten auf den Algebren der möglichen Welten die Eigenschaften von Basiswahrscheinlichkeiten und Belief-Funktionen aus der Dempster-Shafer Theorie aufweisen und auch Dempsters Kombinationsregel eine logische Entsprechung und Rechtfertigung besitzt.

Die Motivation für diese Vorgehensweise war die Beobachtung, daß ein Formalismus wie die klassische Wahrscheinlichkeitstheorie zwar dazu geeignet ist, die Ergebnisse kontrollierter Experimente unter Laborbedingungen zu repräsentieren, bei der Modellierung von Realweltszenarien jedoch Defizite aufweist. In dieser Theorie wird eine Evidenz \mathcal{E} nämlich behandelt, indem von einer Wahrscheinlichkeitsverteilung P zur *bedingten Wahrscheinlichkeit* $P(\cdot|\mathcal{E})$ übergegangen wird. Da auch diese eine totale Funktion ist, ist es somit möglich, den neuen Wahrscheinlichkeitswert für *jedes* Ereignis zu berechnen. Dies bedeutet also, daß eine bestimmte Evidenz immer den gesamten Ereignisraum beeinflusst und dieser Einfluß auch quantifizierbar ist.

Im Gegensatz dazu kann unter realen Bedingungen jede Evidenz \mathcal{E} drei mögliche Auswirkungen auf das *Wissen* eines Agenten bzgl. einer bestimmten Aussage haben: Entweder erlaubt \mathcal{E} , auf p oder die Negation $\neg p$ zu schließen, oder \mathcal{E} ist zu schwach, um irgendeine Aussage bzgl. der Wahrheit von p treffen zu können. Mittels Modaloperatoren könnte diese Situation durch die Formeln $\mathbf{K}p$, $\mathbf{K}\neg p$ und $\mathbf{I}p$ beschrieben werden, wobei \mathbf{K} für Wissen und \mathbf{I} für Ignoranz oder Nichtwissen bzgl. eines Satzes steht.

Betrachtet man diese Aussagen als Ereignisse mit einer bestimmten Wahrscheinlichkeit, so ergibt sich

$$P(\mathbf{K}p) + P(\mathbf{K}\neg p) + P(\mathbf{I}p) = 1. \quad (4.1)$$

Beschränkt man den Wert für $\mathbf{I}p$ auf 0, so erhält man die wahrscheinlichkeitstheoretische Sicht mit

$$P(\mathbf{K}\neg p) = 1 - P(\mathbf{K}p). \quad (4.2)$$

Andernfalls ergibt sich $P(\mathbf{K}p) + P(\mathbf{K}\neg p) \leq 1$, wodurch deutlich wird, daß eine Evidenz zugunsten einer Aussage p nicht notwendigerweise auch Einfluß auf das Wissen über $\neg p$ hat, d.h. es besteht kein direkter funktionaler Zusammenhang wie in (4.2). Verallgemeinert bedeutet dies, daß eine Evidenz \mathcal{E} immer nur Informationen bzgl. der Wahrheit *einiger* Aussagen liefert, über andere jedoch keinerlei Hinweise gibt.¹

Dies spiegelt sich auch darin wider, daß das Ergebnis eines Experimentes unter “realen” Bedingungen nicht unbedingt als ein Elementarereignis klassifizierbar ist. Vielmehr ist es oft der Fall, daß nur eine schwächere Aussage – etwa die Disjunktion mehrerer solcher elementaren Ereignisse – ableitbar ist. In solchen Fällen existiert jedoch immer ein eindeutig bestimmter “stärkster” Satz, der für den Agenten herleitbar ist. Ist dieser in der Wahrscheinlichkeitstheorie immer ein Atom – mengentheoretisch gesehen also eine einelementige Menge von Alternativen – so bildet der Übergang zu *beliebigen* Ereignissen als Ergebnis eines Experiments die Basis für die angestrebte Modellierung von Unwissenheit in der Theorie des evidenzbasierten Schließens. Diese Theorie stellt somit die Tatsache in den Mittelpunkt, daß Evidenz *nicht die Welt selbst*, sondern das *Wissen eines Agenten über diese Welt* verändert.

¹Eine ähnliche Motivation, nämlich die mangelnde Fähigkeit der Wahrscheinlichkeitstheorie, Unwissenheit zu repräsentieren und zwischen fehlendem Glauben und Zweifel zu unterscheiden, lag der Entwicklung des *Certainty-Factor* Ansatzes zugrunde [Shortliffe und Buchanan, 1975; Shortliffe, 1976].

Dem Konzept Ruspinis in [1986] folgend, wird nun zunächst die logische Basis gelegt, bevor dann detailliert der Zusammenhang zwischen möglichen Welten, Wahrscheinlichkeiten und evidenztheoretischen Funktionen betrachtet wird. Sofern nicht anders gekennzeichnet, stammen alle Definitionen und Theoreme dieses Abschnittes aus [Ruspini, 1986].

4.1.1 Die epistemische Logik

Sei ein endliches Alphabet \mathcal{A} mit den speziellen Symbolen \top und \perp gegeben.

Definition 4.1.1 (Satzraum)

Die nach den folgenden Regeln über \mathcal{A} gebildeten Formeln oder Sätze bilden den *Satzraum* (sentence space) \mathcal{S} :

Jedes Element von \mathcal{A} ist eine Formel.

Sind α und β Formeln, so auch $\alpha \wedge \beta$, $\alpha \vee \beta$, $\neg\alpha$, $\alpha \rightarrow \beta$ und $\mathbf{K}\alpha$.

Beinhaltet eine Formel $\alpha \in \mathcal{S}$ kein Vorkommen von \mathbf{K} , so heißt α *objektiv*, andernfalls *epistemisch*. Die Menge aller objektiven Sätze aus \mathcal{S} wird als $Obj(\mathcal{S})$ bezeichnet.

Definition 4.1.2 (Interpretation)

Eine *Interpretation* für \mathcal{S} ist eine Abbildung $\mathcal{W} : \mathcal{S} \rightarrow \{T, F\}$. Eine Formel α heißt *wahr in \mathcal{W}* , falls $\mathcal{W}(\alpha) = T$. Andernfalls heißt α *falsch in \mathcal{W}* .

Um einen möglichen Zustand der Welt in dieser epistemischen Logik zu beschreiben, muß eine solche Interpretation eine Reihe von Bedingungen erfüllen:

Definition 4.1.3 (mögliche Welt, Universum)

Eine Interpretation \mathcal{W} heißt *mögliche Welt* für \mathcal{S} , wenn sie die folgenden Axiome erfüllt:

- (M1) Alle aussagenlogischen Axiome sind wahr in \mathcal{W} , wobei \top den immer wahren und \perp den immer falschen Satz bezeichnet.
- (M2) Wenn $\mathbf{K}\alpha$ wahr in \mathcal{W} ist, dann auch α .
- (M3) Wenn $\mathbf{K}\alpha$ wahr in \mathcal{W} ist, dann auch $\mathbf{K}\mathbf{K}\alpha$. (positive Introspektion)
- (M4) Wenn $\mathbf{K}(\alpha \rightarrow \beta)$ wahr in \mathcal{W} ist, dann auch $\mathbf{K}\alpha \rightarrow \mathbf{K}\beta$.
- (M5) Wenn α ein Axiom ist, dann auch $\mathbf{K}\alpha$.
- (M6) Wenn $\neg\mathbf{K}\alpha$ wahr in \mathcal{W} ist, dann auch $\mathbf{K}\neg\mathbf{K}\alpha$. (negative Introspektion)

Die Menge aller möglichen Welten für \mathcal{S} heißt das *Universum* und wird mit $\mathcal{U}(\mathcal{S})$ bezeichnet.

Die durch die Axiomenschemata (M1) – (M6) beschriebene Logik ist äquivalent zu S5, wobei der Wissensoperator \mathbf{K} dem Notwendigkeitsoperator \Box entspricht. Objektive Sätze in dieser Logik sind durch eine *kompositionale Semantik* gekennzeichnet, d.h. der Wahrheitswert einer Formel ist nach den Gesetzen der Logik funktional von den Wahrheitswerten ihrer atomaren Teilformeln abhängig. Im Gegensatz dazu genügt es für eine epistemische Formel nicht, einfachere Formeln zu betrachten. So kann beispielsweise der Wahrheitswert von $\mathbf{K}(\alpha \vee \beta)$ nicht notwendigerweise aus den Wahrheitswerten für α und β bestimmt werden.

Ein weiteres wichtiges Konzept innerhalb dieser Logik stellt die *logische Implikation* dar. Dabei stehen zwei Formeln α und β in dieser Relation $\alpha \Rightarrow \beta$ zueinander, falls β *ausschließlich* aufgrund der Axiome der epistemischen Logik aus α herleitbar ist, also keine weiteren extralinguistischen Formeln benötigt werden (beispielsweise gilt $\alpha_1 \Rightarrow \alpha_1 \vee \alpha_2$). In jeder möglichen Welt, in der α gilt, gilt dann *notwendigerweise* auch β . Falls $\alpha \not\Rightarrow \beta$, dann gibt es eine mögliche Welt, in der α , nicht aber β gilt. Der Wahrheitswert von β muß in einem solchen Fall unter Berücksichtigung anderer, nicht *notwendigerweise* wahrer Formeln ermittelt werden.

Auf der syntaktischen Ebene werden solche logischen Implikationen $\alpha \Rightarrow \beta$ als *Axiome* $\alpha \rightarrow \beta$ behandelt. Gemäß (M5) folgt daraus auch $\mathbf{K}(\alpha \rightarrow \beta)$, so daß der Agent nicht nur spezifisches anwendungsabhängiges Wissen besitzt, sondern auch die Gesetze der epistemischen Logik kennt.

Definition 4.1.4 (logische Äquivalenz)

Zwei Formeln α und β heißen genau dann *logisch äquivalent*, wenn $\alpha \Rightarrow \beta$ und $\beta \Rightarrow \alpha$. Dies wird mit $\alpha \Leftrightarrow \beta$ bezeichnet.

Offensichtlich ist \Leftrightarrow eine Äquivalenzrelation, die die folgende Klasseneinteilung der objektiven Formeln induziert:

Definition 4.1.5 (Ereignisraum)

Der Quotientenraum $Obj(\mathcal{S})/\Leftrightarrow$ der objektiven Formeln modulo der oben definierten Äquivalenzrelation heißt *Ereignisraum* (*frame of discernment*) und wird mit $\Phi(\mathcal{S})$ bezeichnet.

Im folgenden werden die Äquivalenzklassen $[\alpha] = \{\beta \in Obj(\mathcal{S}) \mid \alpha \Leftrightarrow \beta\}$ aus $\Phi(\mathcal{S})$ mit ihren Repräsentanten α identifiziert.

Anmerkung: $\Phi(\mathcal{S})$ bildet zusammen mit den logischen Operationen \wedge , \vee und \neg (ausgeführt auf den Repräsentanten der Äquivalenzklassen $[\alpha]$) die sogenannte *Lindenbaumalgebra*. Die einzelnen Klassen bilden ihre Atome.

4.1.2 Mögliche Welten und epistemische Zustände

Die Menge der möglichen Welten dieser Logik kann durch die Angabe einer Erreichbarkeitsrelation strukturiert werden. Dabei wird das Leibnizsche Konzept der Not-

wendigkeit als Wahrheit in *allen* möglichen Welten relativiert zur Wahrheit in *allen erreichbaren* Welten (siehe dazu auch [Chellas, 1980, Kapitel 3]).

Definition 4.1.6 (epistemische Äquivalenz, Erreichbarkeitsrelation)

Zwei mögliche Welten $\mathcal{W}_1, \mathcal{W}_2$ heißen *epistemisch äquivalent* ($\mathcal{W}_1 \sim \mathcal{W}_2$), wenn für jede objektive Formel $\alpha \in \text{Obj}(\mathcal{S})$ gilt: $\mathbf{K}\alpha$ ist genau dann wahr in \mathcal{W}_1 , wenn $\mathbf{K}\alpha$ auch in \mathcal{W}_2 wahr ist. Die Relation \sim wird als *Erreichbarkeitsrelation* bezeichnet.

Offensichtlich ist \sim eine Äquivalenzrelation auf dem Universum $\mathcal{U}(\mathcal{S})$. Dies ist somit konsistent mit der Wahl der modallogischen Basis S5, die durch eine Erreichbarkeitsrelation mit dieser Eigenschaft charakterisiert ist.

Die Äquivalenzklassen dieser Relation stellen Mengen möglicher Welten dar, in denen der Agent jeweils über dasselbe Wissen verfügt. Die objektiven Formeln, die den eigentlichen Weltzustand beschreiben, werden in dieser Klasseneinteilung nicht berücksichtigt. Dies spiegelt die im vorigen Abschnitt getroffene Feststellung wider, daß Evidenz in dieser Theorie nicht den Weltzustand, sondern das Wissen darüber verändert und somit mögliche Welten nur anhand der Menge des vorhandenen Wissens unterschieden werden.

Definition 4.1.7 (epistemischer Raum, epistemischer Zustand)

Der Quotientenraum $\mathcal{U}(\mathcal{S})/\sim$ der Menge $\mathcal{U}(\mathcal{S})$ aller möglichen Welten für \mathcal{S} modulo dieser Erreichbarkeitsrelation heißt der *epistemische Raum* von \mathcal{S} und wird mit $\Sigma(\mathcal{S})$ bezeichnet. Die einzelnen Elemente von $\Sigma(\mathcal{S})$ heißen *epistemische Zustände*.

Der folgende Satz ist von fundamentaler Bedeutung für die Theorie des evidenzbasierten Schließens. Er bildet die Grundlage für den Prozeß der “Auswertung” eines Experimentes in dem Sinne, daß der Agent versucht, den “stärksten” Satz abzuleiten, den die Ergebnisse des Experimentes – d.h. die neue Evidenz – zulassen.

Satz 4.1.1 *Es gibt eine injektive Abbildung $\mathbf{M} : \Sigma(\mathcal{S}) \rightarrow \Phi(\mathcal{S})$, die jedem epistemischen Zustand e eine bis auf logische Äquivalenz eindeutig bestimmte objektive Formel $\gamma = \mathbf{M}(e)$ zuordnet, so daß für jede mögliche Welt $\mathcal{W} \in e$ und jede objektive Formel β gilt: $\mathbf{K}\beta$ ist genau dann wahr in \mathcal{W} , wenn $\gamma \Rightarrow \beta$.*

Beweis: Offensichtlich genügt es, den Beweis für eine feste Welt $\mathcal{W} \in e$ zu führen, da alle Elemente von e dieselbe Menge objektiver Sätze α mit $\mathbf{K}\alpha$ beinhalten.

Seien also $\mathcal{W} \in e$ beliebig, aber fest, und $\{\alpha_1, \dots, \alpha_n\}$ die Menge aller objektiven Formeln α , für die $\mathbf{K}\alpha$ in \mathcal{W} wahr ist (alle α_i seien paarweise nicht logisch äquivalent). Genauer ist jedes der α_i der Repräsentant einer Klasse $[\alpha_i]$ logisch äquivalenter Formeln aus $\Phi(\mathcal{S})$ (siehe Bemerkung zu Definition 4.1.5). Die Kardinalität n dieser Menge ist endlich, da auch das zugrundeliegende Alphabet \mathcal{A} endlich ist.

Dann ist $\gamma_0 = \alpha_1 \wedge \dots \wedge \alpha_n$ eine objektive Formel. Gemäß dieser Konstruktion gilt dann: wenn $\mathbf{K}\alpha$ wahr ist in \mathcal{W} , dann $\gamma_0 \Rightarrow \alpha$.

Gilt umgekehrt $\gamma \Rightarrow \alpha$, so ist $\gamma \rightarrow \alpha$ ein Axiom. Gemäß **(M5)** gilt dann $\mathbf{K}(\gamma \rightarrow \alpha)$, und mit **(M4)** folgt $\mathbf{K}\alpha$. Somit ist $\gamma = \gamma_0$ die gesuchte Formel.

Seien nun $e, e' \in \Sigma(\mathcal{S})$. Falls $\mathbf{M}(e) = \mathbf{M}(e')$, gelten in je zwei Welten $\mathcal{W}, \mathcal{W}'$ aus e bzw. e' die gleichen Formeln $\mathbf{K}\alpha$. Somit gilt $\mathcal{W} \sim \mathcal{W}'$ und $e = e'$. Also ist \mathbf{M} injektiv.

Es bleibt die Eindeutigkeit von γ zu zeigen. Seien dazu γ_1, γ_2 zwei objektive Formeln, die den Satz erfüllen. Dann ist auch $\gamma_1 \wedge \gamma_2$ objektiv, und gemäß dem Satz gilt $\gamma_1 \Rightarrow \gamma_1 \wedge \gamma_2$ und $\gamma_2 \Rightarrow \gamma_1 \wedge \gamma_2$. Da aber auch umgekehrt gilt, daß $\gamma_1 \wedge \gamma_2 \Rightarrow \gamma_1$ und $\gamma_1 \wedge \gamma_2 \Rightarrow \gamma_2$, sind beide Formeln logisch äquivalent. \square

Die Formel $\gamma = \mathbf{M}(e)$ ist die spezifischste objektive Formel, die dem Agenten in den in e enthaltenen Welten bekannt ist. Die Umkehrabbildung zu \mathbf{M} wird mit

$$\mathbf{e} : \Phi(\mathcal{S}) \rightarrow \Sigma(\mathcal{S})$$

bezeichnet.

Notation: Als syntaktisches Äquivalent zur Funktion \mathbf{e} wird der Modaloperator \mathbf{K}_e eingeführt mittels

$$\mathbf{K}_e \alpha = \mathbf{K}\alpha \wedge \bigwedge_{\substack{\beta \in \Phi(\mathcal{S}) \\ \beta \Rightarrow \alpha \\ \beta \not\Rightarrow \alpha}} \neg \mathbf{K}\beta. \quad (4.3)$$

$\mathbf{K}_e \alpha$ drückt somit aus, daß der Agent zwar α , aber keine *stärkere* objektive Aussagen β weiß. Die Abbildung \mathbf{e} liefert genau die Einteilung von $\mathcal{U}(\mathcal{S})$ in die Äquivalenzklassen modulo \sim von $\Sigma(\mathcal{S})$:

Lemma 4.1.1 Für alle Welten $\mathcal{W}_1, \mathcal{W}_2 \in \mathcal{U}(\mathcal{S})$ mit $\mathbf{M}([\mathcal{W}_1]) = \gamma_1$ und $\mathbf{M}([\mathcal{W}_2]) = \gamma_2$, wobei $[x]$ die Äquivalenzklasse von x modulo \sim bezeichnet, gilt:

$$\mathcal{W}_1 \sim \mathcal{W}_2 \iff \gamma_1 = \gamma_2 \iff \mathbf{e}(\gamma_1) = \mathbf{e}(\gamma_2).$$

Definition 4.1.8 (Wahrheitsmenge, Unterstützungsmenge)

Die Menge aller möglichen Welten in $\mathcal{U}(\mathcal{S})$, in denen α wahr ist, heißt die *Wahrheitsmenge* $\mathbf{t}(\alpha)$ von α .

Die Menge aller möglichen Welten in $\mathcal{U}(\mathcal{S})$, in denen $\mathbf{K}\alpha$ mit $\alpha \in \Phi(\mathcal{S})$ wahr ist, ist die *Unterstützungsmenge* $\mathbf{k}(\alpha)$ von α .

Satz 4.1.2 Sei $\alpha \in \Phi(\mathcal{S})$. Dann gilt:

$$\mathbf{k}(\alpha) = \bigcup_{\beta \Rightarrow \alpha} \mathbf{e}(\beta). \quad (4.4)$$

Der Beweis folgt unmittelbar aus Satz 4.1.1.

Satz 4.1.3 Sei $\alpha \in \Phi(\mathcal{S})$. Dann gilt:

$$\mathbf{e}(\alpha) = \mathbf{k}(\alpha) \cap \bigcup_{\substack{\beta \Rightarrow \alpha \\ \beta \not\Leftarrow \alpha}} \overline{\mathbf{k}(\beta)} \quad (4.5)$$

$$\overline{\mathbf{k}(\alpha)} = \bigcup_{\beta \not\Leftarrow \alpha} \mathbf{e}(\beta) \quad (4.6)$$

$$\overline{\mathbf{k}(\alpha)} = \bigcup_{\beta \not\Leftarrow \alpha} \mathbf{k}(\beta) \quad (4.7)$$

4.1.3 Epistemische Zustände und Wahrscheinlichkeiten

In diesem Abschnitt werden spezielle Algebren über dem Universum $\mathcal{U}(\mathcal{S})$ der möglichen Welten betrachtet. Dabei wird sich zeigen, daß bestimmte Wahrscheinlichkeiten auf diesen Algebren die Eigenschaften von Basiswahrscheinlichkeiten und Belief-Funktionen aus der Dempster-Shafer Theorie besitzen. Mit Hilfe der Konzepte der unteren und oberen Wahrscheinlichkeiten erhalten diese eine eindeutige Semantik, wodurch ein wesentlicher Kritikpunkt an der DST beseitigt werden kann.

Definition 4.1.9 (epistemische Algebra, Wahrheitsalgebra)

Die kleinste Teilmengenalgebra Ω_E von $\mathcal{U}(\mathcal{S})$, die die Klasse der Unterstützungsmengen $\mathbf{k}(\alpha)$ mit $\alpha \in \Phi(\mathcal{S})$ enthält, heißt die *epistemische Algebra*.

Die kleinste Teilmengenalgebra Ω_T von $\mathcal{U}(\mathcal{S})$, die die Klasse der Wahrheitsmengen $\mathbf{t}(\alpha)$ mit $\alpha \in \Phi(\mathcal{S})$ enthält, heißt die *Wahrheitsalgebra*.

Gemäß Gleichung (4.4) besteht jedes nichtleere Element von Ω_E aus einer Vereinigung epistemischer Zustände $\mathbf{e}(\alpha)$. Diese Äquivalenzklassen $\mathbf{e}(\alpha)$ sind die Atome von Ω_E , wie leicht einzusehen ist: Jedes Element $\mathbf{k}(\alpha)$ in Ω_E besteht aus der Vereinigung solcher $\mathbf{e}(\alpha')$, und aufgrund der Definition von \mathbf{e} gilt $\mathbf{e}(\alpha_1) \cap \mathbf{e}(\alpha_2) = \emptyset$ für $\alpha_1 \not\Leftarrow \alpha_2$ und $\mathbf{e}(\alpha_1) \cap \mathbf{e}(\alpha_2) = \mathbf{e}(\alpha_1)$ sonst.

Definition 4.1.10 (Kern, Hülle)

Für eine Teilmengenalgebra Ω einer Menge X heißt die Abbildung

$$\mathcal{K}_\Omega : 2^X \rightarrow \Omega,$$

die jeder Teilmenge $\omega \subseteq \Omega$ das größte in ω enthaltene Element von Ω zuordnet, der *Kern von 2^X in Ω* . $\mathcal{K}_\Omega(\omega)$ ist der *Kern von ω in Ω* .

Die *Hülle (cover) von 2^X in Ω* ist die Abbildung

$$\mathcal{C}_\Omega : 2^X \rightarrow \Omega,$$

die jeder Teilmenge $\omega \subseteq \Omega$ das kleinste Element von Ω zuordnet, das ω enthält. $\mathcal{C}_\Omega(\omega)$ ist die *Hülle von ω in Ω* .

Satz 4.1.4 Der Kern von $\mathbf{t}(\alpha) \in \mathcal{U}(\mathcal{S})$ in Ω_E ist $\mathbf{k}(\alpha)$.

Bei der Erweiterung einer Wahrscheinlichkeit von einer Subalgebra auf eine größere Algebra spielen die Konzepte der unteren und oberen Wahrscheinlichkeit eine entscheidende Rolle (siehe dazu auch Definition 2.2.2)

Definition 4.1.11 (untere, obere Wahrscheinlichkeit)

Sei P eine Wahrscheinlichkeitsfunktion auf einer Teilmengenalgebra Ω einer Menge X . Dann heißt die Funktion

$$\begin{aligned} P_* : 2^X &\rightarrow [0, 1] \\ \omega &\mapsto P(\mathcal{K}_\Omega(\omega)) \end{aligned}$$

die durch P induzierte untere Wahrscheinlichkeit auf 2^X .

Die durch P induzierte obere Wahrscheinlichkeit ist die Funktion

$$\begin{aligned} P^* : 2^X &\rightarrow [0, 1] \\ \omega &\mapsto P(\mathcal{C}_\Omega(\omega)). \end{aligned}$$

Beide Begriffe sind durch die folgende Gleichung miteinander verknüpft:

$$P^*(\omega) = 1 - P_*(\bar{\omega}). \quad (4.8)$$

Die Bedeutung von P_* und P^* liegt in der Tatsache, daß diese die schärfsten Schranken für eine Wahrscheinlichkeitsfunktion auf der erweiterten Algebra darstellen. Der folgende Satz wird in einer Version von Halpern und Fagin aus [1992] wiedergegeben, da diese Formulierung die Eigenschaft der Optimalität der Schranken deutlicher macht. Zunächst soll jedoch der Begriff der *Erweiterung* eines Wahrscheinlichkeitsraumes exakt definiert werden.

Definition 4.1.12 (Erweiterung eines Wahrscheinlichkeitsraums)

Sei (Ω, \mathcal{E}, P) ein Wahrscheinlichkeitsraum. Dann ist $(\Omega, \mathcal{E}', P')$ eine *Erweiterung* von (Ω, \mathcal{E}, P) , wenn $\mathcal{E} \subseteq \mathcal{E}'$ und $P'(A) = P(A)$ für alle $A \in \mathcal{E}$. Entsprechend wird P' als Erweiterung von P bezeichnet.

Satz 4.1.5 [Halpern und Fagin, 1992]

Sei (X, Ω', \tilde{P}) eine Erweiterung des Wahrscheinlichkeitsraums (X, Ω, P) . Dann gilt:

$$P_*(\omega') \leq \tilde{P}(\omega') \leq P^*(\omega')$$

für alle $\omega' \in \Omega'$. Außerdem existieren Erweiterungen (X, Ω_1, P_1) und (X, Ω_2, P_2) von (X, Ω, P) , so daß

$$P_1(\omega_1) = P_*(\omega_1) \text{ und } P_2(\omega_2) = P^*(\omega_2)$$

für alle $\omega_1 \in \Omega_1$ und $\omega_2 \in \Omega_2$.

Beweis: Die Beweisidee besteht darin, in einer iterativen Konstruktion jeweils ein Element ω' aus Ω' zu Ω hinzuzunehmen und auf der resultierenden Algebra Ω_1 folgende Funktion \tilde{P}_1 zu definieren (o.B.d.A. sei ω_1 das erste solche Element von Ω'):

$$\begin{aligned}\tilde{P}_1(\omega) &= 0, \text{ falls } \omega \subseteq (\omega_1 \cap \overline{\mathcal{K}_\Omega(\omega_1)}) \\ \tilde{P}_1(\omega) &= P(\omega \cap \mathcal{K}_\Omega(\omega_1)), \text{ falls } \omega \subseteq \mathcal{K}_\Omega(\omega_1) \\ \tilde{P}_1(\omega) &= \max_{\Delta(\omega)} P(\sigma), \text{ falls } \omega \cap \omega_1 = \emptyset.\end{aligned}$$

In der letzten Zeile wird das Maximum dabei über der Menge

$$\Delta(\omega) = \{\sigma \in \Omega \mid \sigma \cap \mathcal{K}_\Omega(\omega_1) = \emptyset, \sigma \cap \overline{\omega_1} = \omega \cap \overline{\omega_1}\}$$

gebildet. Dies dient dazu, \tilde{P}_1 auf $\overline{\omega_1}$ zu definieren, während die ersten beiden Gleichungen festlegen, daß nur der Kern von ω_1 in Ω zu dessen Wahrscheinlichkeit beiträgt und die Konsistenz mit P gewahrt bleibt. Durch Additivität kann \tilde{P}_1 auf ganz Ω_1 erweitert werden.

Wird diese Konstruktion für alle $\omega' \in \Omega' \setminus \Omega$ durchgeführt, so erhält man eine Wahrscheinlichkeitsfunktion \tilde{P} auf Ω' mit folgenden Eigenschaften:

$$\tilde{P}(\omega_1) = P_*(\omega_1) \tag{4.9}$$

$$\tilde{P}(\omega) \geq P_*(\omega), \text{ falls } \omega \in \Omega' \setminus \Omega \tag{4.10}$$

$$\tilde{P}(\omega) \geq P(\omega), \text{ falls } \omega \in \Omega. \tag{4.11}$$

Somit ist gezeigt, daß P_* eine untere Schranke für \tilde{P} darstellt ((4.10) und (4.11)) und außerdem nicht verbessert werden kann (4.9). Das heißt, es kann keine untere Schranke P'_* mit $P'_*(\omega_1) > P_*(\omega_1)$ geben, da – wie die obige Konstruktion zeigt – dieser Wert tatsächlich angenommen werden kann. \square

Die Wahrscheinlichkeit \tilde{P} ist eine Erweiterung von P . Satz 4.1.5 besagt, daß die untere Wahrscheinlichkeit P_* gleichzeitig die untere Schranke $P_{\mathcal{L}^*}$ der Klasse \mathcal{L} aller Erweiterungen \tilde{P} von P ist. Aufgrund der Eigenschaften von P_* (siehe Lemma 2.2.1, (U4)) ist diese Klasse vom Typ 2 (vergleiche Definition 2.2.5).

Auf dieser Basis kann nun die Verbindung zu den Funktionen der Dempster-Shafer Theorie hergestellt werden:

Definition 4.1.13 (Basiswahrscheinlichkeit)

Sei P eine Wahrscheinlichkeitsfunktion auf der epistemischen Algebra Ω_E von $\mathcal{U}(\mathcal{S})$. Dann wird P als *Basiswahrscheinlichkeit* auf $\mathcal{U}(\mathcal{S})$ bezeichnet.

Anmerkungen: 1. Betrachtet man die epistemischen Zustände aus $\Sigma(\mathcal{S})$ als Teilmengen von $\mathcal{U}(\mathcal{S})$, so kann P aus der obigen Definition auch als Wahrscheinlichkeit über $\Sigma(\mathcal{S})$ betrachtet werden. Dabei gilt $\sum_{\mathbf{e} \in \Sigma(\mathcal{S})} P(\mathbf{e}) = 1$, da $\Sigma(\mathcal{S})$ eine Partitionierung von $\mathcal{U}(\mathcal{S})$ darstellt.

2. Eine Übereinstimmung von P aus der obigen Definition mit einer Basiswahrscheinlichkeit aus der Dempster-Shafer Theorie besteht nur insofern, als die mit P assoziierte diskrete Wahrscheinlichkeitsverteilung in Ω_E genau den einzelnen $\mathbf{e}(\alpha)$ von Null verschiedene Werte zuordnet, die in Ω_E zwar die Atome bilden, in $\mathcal{U}(\mathcal{S})$ jedoch nicht-atomare Ereignisse darstellen. Das eigentliche Äquivalent bildet die im folgenden definierte Wahrscheinlichkeitsmasse:

Definition 4.1.14 (Wahrscheinlichkeitsmasse)

Die Funktion

$$m : \Phi(\mathcal{S}) \rightarrow [0, 1] \quad \text{mit} \quad m(\alpha) = P(\mathbf{e}(\alpha))$$

heißt die mit P assoziierte Wahrscheinlichkeitsmasse in $\Phi(\mathcal{S})$.

Lemma 4.1.2 $\sum_{\alpha \in \Phi(\mathcal{S})} m(\alpha) = 1$.

Beweis:

$$\begin{aligned} \sum_{\alpha \in \Phi(\mathcal{S})} m(\alpha) &= P\left(\bigcup_{\alpha \in \Phi(\mathcal{S})} \mathbf{e}(\alpha)\right), \quad \text{da } \mathbf{e}(\alpha_1) \cap \mathbf{e}(\alpha_2) = \emptyset, \alpha_1 \not\approx \alpha_2 \\ &= P(\mathcal{U}(\mathcal{S})), \quad \text{da die } \mathbf{e}(\alpha) \text{ das Universum } \mathcal{U}(\mathcal{S}) \text{ partitionieren} \\ &= 1 \end{aligned}$$

□

Auf der Basis von P lassen sich die folgenden Funktionen definieren:

Definition 4.1.15 (Unterstützungsfunktion, Plausibilität)

Die Funktion $Bel : \Phi(\mathcal{S}) \rightarrow [0, 1]$ mit

$$Bel(\alpha) = P(\mathbf{k}(\alpha))$$

heißt die mit P assoziierte Unterstützungsfunktion in $\Phi(\mathcal{S})$, und die Funktion $Pl : \Phi(\mathcal{S}) \rightarrow [0, 1]$ mit

$$Pl(\alpha) = 1 - Bel(\neg\alpha)$$

heißt die mit P assoziierte Plausibilitätsfunktion in $\Phi(\mathcal{S})$

Anmerkungen: 1. In der Dempster-Shafer Theorie werden Unterstützungsfunktionen üblicherweise als *Belief-Funktionen* bezeichnet.

2. Offensichtlich ist $Pl(\alpha) = 1 - P(\overline{\mathbf{k}(\alpha)})$ die von P induzierte obere Wahrscheinlichkeit auf $2^{\mathcal{U}(\mathcal{S})}$.

Lemma 4.1.3 Aus Definition 4.1.15 folgt:

$$Bel(\alpha) = \sum_{\beta \Rightarrow \alpha} m(\beta) \tag{4.12}$$

$$Pl(\alpha) = \sum_{\beta \not\Rightarrow \neg\alpha} m(\beta) \tag{4.13}$$

Die Konzepte der oberen und unteren Wahrscheinlichkeit sowie der Unterstützungs- und Plausibilitätsfunktionen lassen sich auf folgende Weise miteinander in Beziehung setzen: Sei P eine Wahrscheinlichkeitsfunktion auf der epistemischen Algebra Ω_E . Dann gilt:

$$\begin{aligned}
\underline{Bel}(\alpha) &= \sum_{\beta \Rightarrow \alpha} m(\beta) && \text{nach (4.12)} \\
&= \sum_{\beta \Rightarrow \alpha} P(\mathbf{e}(\beta)) && \text{nach Def. 4.1.14} \\
&= P\left(\bigcup_{\beta \Rightarrow \alpha} \mathbf{e}(\beta)\right) && \text{wg. paarweiser Disjunktheit der } \mathbf{e}(\beta) \\
&= P(\mathbf{k}(\alpha)) && \text{nach (4.4)} \\
&= P_*(\mathbf{t}(\alpha)) && \text{nach Satz 4.1.4} \\
&\leq \underline{P(\mathbf{t}(\alpha))}
\end{aligned}$$

Eine Unterstützungs- oder Belief-Funktion ist somit die schärfste untere Schranke für die Wahrscheinlichkeit der Wahrheit einer objektiven Formel α , solange Konsistenz zwischen den Wahrscheinlichkeiten auf Ω_E und Ω_T vorausgesetzt wird. Entsprechend kann gezeigt werden, daß die Plausibilitätsfunktion der oberen Schranke entspricht:

$$\begin{aligned}
\underline{Pl}(\alpha) &= \sum_{\beta \not\Rightarrow \neg\alpha} m(\beta) && \text{nach (4.13)} \\
&= \sum_{\beta \not\Rightarrow \neg\alpha} P(\mathbf{e}(\beta)) && \text{nach Def. 4.1.14} \\
&= P\left(\bigcup_{\beta \not\Rightarrow \neg\alpha} \mathbf{e}(\beta)\right) && \text{wg. paarweiser Disjunktheit der } \mathbf{e}(\beta) \\
&= P(\overline{\mathbf{k}(\neg\alpha)}) && \text{nach (4.6)} \\
&= 1 - P(\mathbf{k}(\neg\alpha)) \\
&= 1 - P_*(\mathbf{t}(\neg\alpha)) && \text{nach Satz 4.1.4} \\
&= P^*(\overline{\mathbf{t}(\neg\alpha)}) && \text{nach (4.8)} \\
&= P^*(\mathbf{t}(\alpha)) \\
&\geq \underline{P(\mathbf{t}(\alpha))}
\end{aligned}$$

Ist es für den Agenten möglich, perfekte Information zu erhalten, gilt also $\alpha \rightarrow \mathbf{K}\alpha$, so ist $\Omega_E = \Omega_T$, d.h. P_* und P^* (und damit Bel und Pl) fallen zusammen, und man befindet sich wieder im klassischen probabilistischen Fall.

Die in diesem Abschnitt eingeführten Wahrscheinlichkeiten möglicher Welten können nun zur Quantifizierung der Wahrscheinlichkeit $\hat{P}(\alpha)$ einer Formel $\alpha \in \Phi(\mathcal{S})$ herangezogen werden, indem ihr der entsprechende Wert für die Menge aller α wahr machenden möglichen Welten in Ω_T zugeordnet wird. Somit ergibt sich speziell für eine Wahrscheinlichkeitsfunktion P auf Ω_T :

$$\hat{P}(\alpha) = \begin{cases} P(\mathbf{t}(\alpha)), & \alpha \in \text{Obj}(\mathcal{S}) \\ \text{Bel}(\beta) = P(\mathbf{k}(\beta)), & \alpha = \mathbf{K}\beta \\ m(\beta) = P(\mathbf{e}(\beta)), & \alpha = \mathbf{K}_e\beta \end{cases} \quad (4.14)$$

Im folgenden wird die spezielle Notation $\hat{P}(\cdot)$ für die Wahrscheinlichkeit über dem Satzraum nicht mehr verwendet werden. Stattdessen wird die Notation $P(\cdot)$ benutzt. Je nach Art des Argumentes (Formel oder Menge von Welten) wird klar sein, welchen Definitionsbereich die entsprechende Wahrscheinlichkeitsfunktion hat.

Um den Sachverhalt aus (4.14) kompakter darstellen zu können, wird das Konzept der *Erfüllungsmenge* eingeführt, das die Operatoren $\mathbf{t}(\cdot)$, $\mathbf{k}(\cdot)$ und $\mathbf{e}(\cdot)$ subsumiert:

Definition 4.1.16 (Erfüllungsmenge)

Die Menge aller möglichen Welten, in denen eine Formel α erfüllt ist, wird als die *Erfüllungsmenge* $\mathbf{T}(\alpha)$ von α bezeichnet. Sie ist induktiv definiert durch

$$\mathbf{T}(\alpha) = \begin{cases} \mathbf{t}(\alpha), & \alpha \in \text{Obj}(\mathcal{S}) \\ \mathbf{k}(\beta), & \alpha = \mathbf{K}\beta \\ \mathbf{e}(\beta), & \alpha = \mathbf{K}_e\beta \\ \mathbf{T}(\beta_1) \cap \mathbf{T}(\beta_2), & \alpha = \beta_1 \wedge \beta_2 \\ \mathbf{T}(\beta_1) \cup \mathbf{T}(\beta_2), & \alpha = \beta_1 \vee \beta_2 \\ \overline{\mathbf{T}(\beta)}, & \alpha = \neg\beta \end{cases}$$

Mit dieser Definition läßt sich (4.14) nun neu formulieren als

$$P(\alpha) = P(\mathbf{T}(\alpha)) \quad (4.15)$$

für *alle* Formeln α .

4.1.4 Kombination von Wissen

Um die Kombination des Wissens zweier voneinander unabhängiger und sich gegenseitig vertrauender Agenten darstellen zu können, müssen einige der Begriffe aus den

vorherigen Abschnitten dieses Kapitels für den Fall der Existenz mehrerer Universen verallgemeinert werden. Dabei werden numerische Indizes wie in \mathbf{K}_1 oder $\Phi(\mathcal{S}_2)$ auftreten, die sich jeweils auf den ersten bzw. zweiten Agenten beziehen. Fehlen solche Indizes, so bezeichnen die entsprechenden Symbole übergeordnete Konzepte, die sich mit dem gemeinsamen Wissen beider Agenten befassen. Die Ausführungen werden sich auf solche Aspekte beschränken, die für die Herleitung und Rechtfertigung von Dempsters Regel notwendig sind.

Anmerkung: Der Begriff der *Unabhängigkeit* soll hier zunächst informal verwendet werden und zum Ausdruck bringen, daß die beiden Agenten über Informationsquellen verfügen, die sich nicht gegenseitig beeinflussen, insbesondere also voneinander verschieden sind. Eine exakte Charakterisierung, die eine probabilistische Interpretation dieses Sachverhaltes erlaubt, wird Gegenstand von Definition 4.1.25 sein.

Definition 4.1.17 (logisches Produkt)

Seien $\mathcal{S}_1, \mathcal{S}_2$ Satzräume. Das *logische Produkt* $\mathcal{S}_1 \otimes \mathcal{S}_2$ beinhaltet alle Formeln aus \mathcal{S}_1 und \mathcal{S}_2 sowie alle Formeln, die sich gemäß Definition 4.1.1 bilden lassen.

Definition 4.1.18 (mögliche Welt, Produktuniversum)

Eine *mögliche Welt* für $\mathcal{S}_1 \otimes \mathcal{S}_2$ ist eine Abbildung $\mathcal{W} : \mathcal{S}_1 \otimes \mathcal{S}_2 \rightarrow \{T, F\}$ mit

(PU1) \mathcal{W} erfüllt die Axiomenschemata (M1) – (M6) aus Definition 4.1.3.

(PU2) Wenn $\alpha \in \mathcal{S}_1 \otimes \mathcal{S}_2$, so ist $\mathbf{K}\alpha$ genau dann wahr in \mathcal{W} , wenn es zwei Formeln $\alpha_1 \in \mathcal{S}_1$ und $\alpha_2 \in \mathcal{S}_2$ gibt, so daß $\mathbf{K}\alpha_i$ wahr ist in \mathcal{W} und $\alpha_1 \wedge \alpha_2 \Rightarrow \alpha$.

Die Menge aller möglichen Welten für $\mathcal{S}_1 \otimes \mathcal{S}_2$ ist das *Produktuniversum* $\mathcal{U}_{\otimes}(\mathcal{S}_1 \otimes \mathcal{S}_2)$.

(PU2) bedeutet, daß bei der Kombination von Wissen kein essentiell *neues* Wissen entstehen kann, das nicht aus demjenigen der beiden Agenten ableitbar wäre.

Definition 4.1.19 (Produktraum)

Das *Produkt* zweier Ereignisräume $\Phi(\mathcal{S}_1)$ und $\Phi(\mathcal{S}_2)$ wird mit $\Phi(\mathcal{S}_1 \otimes \mathcal{S}_2)$ bezeichnet und entspricht dem Quotienten $(\mathcal{S}_1 \otimes \mathcal{S}_2)/\Leftrightarrow$.

Definition 4.1.20 (Cartesische Projektion)

Die Abbildung $\Pi : \mathcal{U}_{\otimes}(\mathcal{S}_1 \otimes \mathcal{S}_2) \rightarrow \mathcal{U}(\mathcal{S}_1) \times \mathcal{U}(\mathcal{S}_2)$ mit $\Pi(\mathcal{W}) = (\mathcal{W}_1, \mathcal{W}_2)$, wobei $\mathcal{W}_i \in \mathcal{U}(\mathcal{S}_i)$ eindeutig bestimmt ist durch

1. $\alpha \in \mathcal{S}_i$ ist genau dann wahr in \mathcal{W}_i , wenn α wahr ist in \mathcal{W} , und
2. $\mathbf{K}_i\alpha$ mit $\alpha \in \Phi(\mathcal{S}_i)$ ist genau dann wahr in \mathcal{W}_i , wenn $\mathbf{K}\alpha$ wahr ist in \mathcal{W} ,

heißt die *Cartesische Projektion* von $\mathcal{U}_{\otimes}(\mathcal{S}_1 \otimes \mathcal{S}_2)$.

Die Abbildung Π , die injektiv ist, zerlegt somit eine Welt \mathcal{W} aus dem Produktuniversum *eindeutig* in ihre Komponenten \mathcal{W}_1 und \mathcal{W}_2 , die jeweils die Welten der einzelnen Agenten und deren Wissen darstellen.

Definition 4.1.21 (marginale Unterstützungs- und epistemische Menge)

Die *marginale Unterstützungsmenge* $\hat{\mathbf{k}}_i(\alpha_i)$ für $\alpha_i \in \Phi(\mathcal{S}_i)$ in $\mathcal{U}_\otimes(\mathcal{S}_1 \otimes \mathcal{S}_2)$ ist die Menge aller möglichen Welten in $\mathcal{U}_\otimes(\mathcal{S}_1 \otimes \mathcal{S}_2)$, in denen $\mathbf{K}\alpha_i$ wahr ist.

Die *marginale epistemische Menge* $\hat{\mathbf{e}}_i(\alpha_i)$ für $\alpha_i \in \Phi(\mathcal{S}_i)$ ist die Menge aller möglichen Welten aus $\mathcal{U}_\otimes(\mathcal{S}_1 \otimes \mathcal{S}_2)$, in denen α_i der spezifischste objektive Satz aus $\Phi(\mathcal{S}_i)$ ist, der dem Agenten bekannt ist.

Mit dieser Definition gilt

$$\hat{\mathbf{k}}_i(\alpha_i) = \bigcup_{\beta \Rightarrow \alpha} \hat{\mathbf{e}}_i(\beta).$$

Auch hier gilt, daß die $\hat{\mathbf{e}}_i(\alpha)$ eine Partition des Produktuniversums $\mathcal{U}_\otimes(\mathcal{S}_1 \otimes \mathcal{S}_2)$ bilden.

Definition 4.1.22 (marginale epistemische Algebra, Produktalgebra)

Die kleinste Algebra von $\mathcal{U}_\otimes(\mathcal{S}_1 \otimes \mathcal{S}_2)$, die die marginalen epistemischen Mengen $\hat{\mathbf{e}}_i(\alpha)$ enthält für $\alpha \in \Phi(\mathcal{S}_i)$, $i = 1, 2$, heißt die *marginale epistemische Algebra* $\Omega_E^i(\mathcal{U}_\otimes)$ für $\Phi(\mathcal{S}_i)$.

Die kleinste Algebra von $\mathcal{U}_\otimes(\mathcal{S}_1 \otimes \mathcal{S}_2)$, die $\Omega_E^1(\mathcal{U}_\otimes)$ und $\Omega_E^2(\mathcal{U}_\otimes)$ enthält, ist die *epistemische Produktalgebra* $\hat{\Omega}_E(\mathcal{U}_\otimes)$ von $\mathcal{U}_\otimes(\mathcal{S}_1 \otimes \mathcal{S}_2)$.

Satz 4.1.6 *Es gibt eine Abbildung*

$$\Gamma : \Phi(\mathcal{S}_1 \otimes \mathcal{S}_2) \rightarrow 2^{\Phi(\mathcal{S}_1) \times \Phi(\mathcal{S}_2)},$$

die jeder Formel $\alpha \in \Phi(\mathcal{S}_1 \otimes \mathcal{S}_2)$ eine Menge von Paaren $(\alpha_1, \alpha_2) \in \Phi(\mathcal{S}_1) \times \Phi(\mathcal{S}_2)$ zuordnet, so daß $\alpha_1 \wedge \alpha_2 \Leftrightarrow \alpha$. Ist $\alpha \not\equiv \alpha'$, so gilt $\Gamma(\alpha) \cap \Gamma(\alpha') = \emptyset$.

Definition 4.1.23 (Kompatibilitätsrelation)

Die Abbildung Γ aus Satz 4.1.6 heißt *Kompatibilitätsrelation* von $\Phi(\mathcal{S}_1 \otimes \mathcal{S}_2)$.

Satz 4.1.7 (Kombinationssatz) *Sei $\alpha \in \Phi(\mathcal{S}_1 \otimes \mathcal{S}_2)$ eine objektive Formel. Dann gilt*

$$\mathbf{e}(\alpha) = \bigcup_{(\alpha_1, \alpha_2) \in \Gamma(\alpha)} [\hat{\mathbf{e}}_1(\alpha_1) \cap \hat{\mathbf{e}}_2(\alpha_2)]. \quad (4.16)$$

(4.16) erinnert bereits an die Form von Dempsters Kombinationsregel und besagt, daß die spezifischsten bekannten objektiven Sätze im Produktsatzraum aus dem jeweils spezifischsten Wissen der beiden Agenten folgen, bzw. daß die Atome der epistemischen Algebra des Produktsatzraumes aus Vereinigungen von Atomen der marginalen epistemischen Algebren bestehen.

Seien nun für $\alpha_1 \in \Phi(\mathcal{S}_1)$ und $\alpha_2 \in \Phi(\mathcal{S}_2)$

$$\begin{aligned}\tilde{\mathbf{e}}_1(\alpha_1) &= \mathbf{e}_1(\alpha_1) \times \mathcal{U}(\mathcal{S}_2) \text{ und} \\ \tilde{\mathbf{e}}_2(\alpha_2) &= \mathcal{U}(\mathcal{S}_1) \times \mathbf{e}_2(\alpha_2).\end{aligned}$$

Dann bezeichnen $\Omega_E^1(\mathcal{U}_x)$ und $\Omega_E^2(\mathcal{U}_x)$ die kleinsten Algebren von $\mathcal{U}(\mathcal{S}_1) \times \mathcal{U}(\mathcal{S}_2)$, die die Mengen der $\tilde{\mathbf{e}}_i(\alpha_i)$ enthalten. Die epistemische Produktalgebra $\hat{\Omega}_E(\mathcal{U}_x)$ ist die kleinste Algebra von $\mathcal{U}(\mathcal{S}_1) \times \mathcal{U}(\mathcal{S}_2)$, die $\Omega_E^1(\mathcal{U}_x)$ und $\Omega_E^2(\mathcal{U}_x)$ umfaßt.

Die $\tilde{\mathbf{e}}_i(\alpha_i)$ entsprechen somit den zylindrischen Erweiterungen von $\mathbf{e}_i(\alpha_i)$ von $\mathcal{U}(\mathcal{S}_i)$ nach $\mathcal{U}(\mathcal{S}_1) \times \mathcal{U}(\mathcal{S}_2)$ und beschreiben das spezifische Wissen der beiden Agenten in einem gemeinsamen Ereignisraum. Ziel wird es nun sein, durch die Wissenskombination aus diesem Raum gerade diejenigen Ereignisse zu extrahieren, die gemäß einer Kompatibilitätsrelation Γ (siehe Definition 4.1.23) miteinander verträglich sind in dem Sinne, daß sie sich nicht gegenseitig ausschließen.

Definition 4.1.24 (epistemische Wahrscheinlichkeit)

Sei $\Pi_\otimes = \Pi(\mathcal{U}_\otimes(\mathcal{S}_1 \otimes \mathcal{S}_2))$ das Bild des Produktuniversums unter Π . Ist nun P eine Wahrscheinlichkeit auf $\hat{\Omega}_E(\mathcal{U}_x)$, so heißt die durch

$$\hat{P}(\omega) = P(\Pi(\omega) | \Pi_\otimes)$$

definierte Funktion \hat{P} die durch Π und P in $\mathcal{U}_\otimes(\mathcal{S}_1 \otimes \mathcal{S}_2)$ induzierte epistemische Wahrscheinlichkeit.

Betrachtet man $\mathcal{U}_\otimes(\mathcal{S}_1 \otimes \mathcal{S}_2)$ als eingebettet in $\mathcal{U}(\mathcal{S}_1) \times \mathcal{U}(\mathcal{S}_2)$ durch die Abbildung Π , so entspricht dieser Übergang zur bedingten Wahrscheinlichkeit $\hat{P} = P(\cdot | \Pi_\otimes)$ exakt der Einschränkung auf all diejenigen Welten, die nach der Kombination noch möglich sind. Die Wahrscheinlichkeit P auf dem Cartesischen Produkt der beiden Universen $\mathcal{U}(\mathcal{S}_i)$ repräsentiert somit das Wissen der beiden Agenten vor der Kombination, während \hat{P} gerade die Vereinigung darstellt, wobei die *beiden* zugängliche Evidenz berücksichtigt wird. Dabei erhalten inkonsistente Paare von Aussagen α_1 und α_2 – für die also $(\alpha_1, \alpha_2) \in \overline{\Pi_\otimes}$ gilt – eine Wahrscheinlichkeit von Null.

Satz 4.1.8 (additive Kombination) *Seien \hat{P} eine Wahrscheinlichkeit auf $\hat{\Omega}_E(\mathcal{U}_x)$ und m die mit ihr assoziierte Wahrscheinlichkeitsmasse. Für $\alpha \in \Phi(\mathcal{S}_1 \otimes \mathcal{S}_2)$ gilt dann*

$$m(\alpha) = \sum_{(\alpha_1, \alpha_2) \in \Gamma(\alpha)} \hat{P}(\tilde{\mathbf{e}}_1(\alpha_1) \cap \tilde{\mathbf{e}}_2(\alpha_2)). \quad (4.17)$$

Ist \hat{P} die durch Π und P induzierte epistemische Wahrscheinlichkeit gemäß Definition 4.1.24, und ist $P(\Pi_\otimes) > 0$, so gilt

$$m(\alpha) = \kappa \sum_{(\alpha_1, \alpha_2) \in \Gamma(\alpha)} P(\tilde{\mathbf{e}}_1(\alpha_1) \cap \tilde{\mathbf{e}}_2(\alpha_2)). \quad (4.18)$$

Dabei ist $\kappa = 1/P(\Pi_\otimes)$ die einzige reelle Konstante, so daß

$$\sum_{\alpha \in \Phi(\mathcal{S}_1 \otimes \mathcal{S}_2)} m(\alpha) = 1.$$

Um nun Dempsters Regel zur Kombination unabhängiger Evidenzen herleiten zu können, muß zunächst der Begriff der Unabhängigkeit formalisiert werden:

Definition 4.1.25 (unabhängige Algebren)

Seien Ω_1, Ω_2 Subalgebren einer Teilmengenalgebra Ω über einer Menge X , P eine Wahrscheinlichkeit auf Ω . Dann heißen Ω_1 und Ω_2 *unabhängig bzgl. P* , falls

$$P(\omega_1 \cap \omega_2) = P(\omega_1) P(\omega_2)$$

für alle $\omega_1 \in \Omega_1, \omega_2 \in \Omega_2$.

Dies bedeutet, daß die Wahrscheinlichkeitswerte auf einer der beiden Algebren nicht funktional von denen auf der anderen Algebra abhängen. Insbesondere beeinflusst die Veränderung der Werte beispielsweise für Ω_1 nicht diejenigen für Ω_2 . Betrachtet man zudem die kleinste Algebra $\Omega_{1,2}$, die sowohl Ω_1 als auch Ω_2 umfaßt, so ist zur vollständigen Spezifikation der Werte von P über $\Omega_{1,2}$ die Angabe der jeweiligen Werte für Ω_1 und Ω_2 ausreichend.

Satz 4.1.9 [Dempster, 1967] *Sei \hat{P} die durch Π und P in $\mathcal{U}_{\otimes}(\mathcal{S}_1 \otimes \mathcal{S}_2)$ induzierte epistemische Wahrscheinlichkeit, wobei $P(\Pi_{\otimes}) > 0$. Seien ferner die beiden marginalen Algebren $\Omega_{\mathcal{E}}^1(\mathcal{U}_{\times})$ und $\Omega_{\mathcal{E}}^2(\mathcal{U}_{\times})$ von $\mathcal{U}_{\otimes}(\mathcal{S}_1 \otimes \mathcal{S}_2)$ unabhängig bzgl. P .*

m sei die mit \hat{P} assoziierte Wahrscheinlichkeitsmasse auf $\Phi(\mathcal{S}_1 \otimes \mathcal{S}_2)$, während m_1 und m_2 die jeweiligen Wahrscheinlichkeitsmassen von P in den Ereignisräumen $\Phi(\mathcal{S}_1)$ bzw. $\Phi(\mathcal{S}_2)$ darstellen. Ist $\alpha \in \Phi(\mathcal{S}_1 \otimes \mathcal{S}_2)$, so gilt

$$m(\alpha) = \kappa \sum_{(\alpha_1, \alpha_2) \in \Gamma(\alpha)} m_1(\alpha_1) m_2(\alpha_2), \quad (4.19)$$

wobei κ die einzige reelle Konstante ist, so daß $\sum_{\alpha \in \Phi(\mathcal{S}_1 \otimes \mathcal{S}_2)} m(\alpha) = 1$.

Beweis: Der Beweis ergibt sich unmittelbar aus Satz 4.1.8 durch die Wahl $\kappa = 1/P(\Pi_{\otimes})$ und die Unabhängigkeit der beiden Algebren $\Omega_{\mathcal{E}}^1(\mathcal{U}_{\times})$ und $\Omega_{\mathcal{E}}^2(\mathcal{U}_{\times})$, die es erlaubt, die Wahrscheinlichkeit

$$P(\tilde{\mathbf{e}}_1(\alpha_1) \cap \tilde{\mathbf{e}}_2(\alpha_2))$$

aus (4.18) in (4.19) durch das Produkt der Einzelwahrscheinlichkeiten zu ersetzen. \square

Somit kann Dempsters Kombinationsregel eine Semantik im Sinne klassischer Wahrscheinlichkeitstheorie gegeben werden, indem das Ergebnis der Kombination als eine Konditionierung bzgl. der Menge aller miteinander konsistenten Ereignisse Π_{\otimes} betrachtet wird.

Die Auswertung eines Experiments durch mehrere voneinander unabhängige Agenten geschieht demnach nach folgendem Schema:

1. Jeder Agent quantifiziert den Einfluß, den das Experiment auf sein Wissen hatte, in einer (marginalen) Algebra, die genau seine Wissenszustände repräsentiert.
2. Die resultierenden marginalen Wahrscheinlichkeiten werden auf den Produktergebnisraum und die Produktalgebra übertragen. Dies ermöglicht den direkten Vergleich der von den Agenten getroffenen Aussagen.
3. Die Kombination dieser Evidenzen wird berechnet, indem die Wahrscheinlichkeit für alle Aussagen, die nicht miteinander kompatibel sind, auf Null gesetzt und bei allen anderen die jeweiligen numerischen Werte akkumuliert werden.

4.1.5 Epistemologische Betrachtungen

Ist der Satzraum groß genug, um die Beobachtungen während eines Experimentes direkt als Formel zu beschreiben, so kann eine Evidenz auch durch die Konditionierung einer epistemischen Wahrscheinlichkeit bzgl. einer Unterstützungsmenge $\mathbf{k}(\alpha)$ dargestellt werden, wobei α die tatsächliche Beobachtung repräsentiert. Entsprechend steht die Kombination zweier Evidenzen für die Ableitung einer Wahrscheinlichkeit $P(.|\mathbf{k}(\alpha_1), \mathbf{k}(\alpha_2))$ aus den Funktionen $P(.|\mathbf{k}(\alpha_1))$ und $P(.|\mathbf{k}(\alpha_2))$.

Die in diesem Kapitel vorgestellte Theorie des evidenzbasierten Schließens beruht auf der Identifizierung von Beobachtungen der Welt mit Wahrscheinlichkeiten in der epistemischen Algebra Ω_E . Das Wissen über die Wahrheit einer Aussage α ist somit gleichbedeutend mit der Existenz einer Evidenz oder Beobachtung, die die Gültigkeit von α unterstützt. Ist diese Evidenz unsicher, so kann der Grad des Vertrauens in α mittels einer Wahrscheinlichkeit quantifiziert werden.

Im Gegensatz zum klassischen probabilistischen Ansatz liefert Evidenz in diesem Sinne auch immer nur Hinweise auf die Gültigkeit *mancher* Fakten, während über andere keinerlei Aussage getroffen werden kann (vergleiche dazu auch die Bedeutung des Operators **I** zu Beginn von Abschnitt 4.1). Somit bedeutet eine Wahrscheinlichkeit von Null für ein Ereignis lediglich, daß es keine unterstützende Evidenz gibt, ohne es jedoch als unmöglich zu klassifizieren. Im Gegensatz dazu greifen klassische Ansätze in unterspezifizierten Situationen, d.h. bei fehlendem Wissen über bestimmte Ereignisse, zu Hilfsmitteln wie der Annahme uniformer Wahrscheinlichkeitsverteilungen. Dies ist im Sinne der vorliegenden Theorie, in der eine Evidenz nicht die Welt, sondern das Wissen darüber verändert, unzulässig, da der Informationsgehalt einer Evidenz verfälscht wird.

4.2 Die Einführung von Konditionalen

Der vorige Abschnitt führte die Theorie des evidenzbasierten Schließens ein, mit deren Hilfe eine wahrscheinlichkeitstheoretische Semantik für die Dempster-Shafer Theorie angegeben werden konnte. Die Basis dafür war eine epistemische Modallogik auf der

Basis von S5, wobei die einzelnen Operationen auf den Ereignisräumen ihrer semantischen Strukturen wie Durchschnittsbildung jeweils ein Pendant in der Logik besaßen – in diesem Fall etwa die Konjunktion. Dies trifft jedoch nicht auf die Konditionierung zu, die nur bei der wahrscheinlichkeitstheoretischen Behandlung der möglichen Welten im Zusammenhang mit bedingten Wahrscheinlichkeiten $P(.|\mathbf{k}(\alpha))$ betrachtet wurde. Die Einführung von *Konditionalen* in die Logik erlaubt sowohl eine syntaktische als auch eine semantische Analyse des Problems der Auswirkung einer Evidenz auf den Hypothesenraum.

Konkret bedeutet dies folgendes: In Abschnitt 4.1 wurde lediglich das Problem der *Kombination* des Wissens zweier Agenten auf einem gemeinsamen Ereignisraum betrachtet. Üblicherweise entsteht das Wissen eines Agenten über die einzelnen Hypothesen jedoch durch Beobachtung von Ereignissen in einem *Evidenzenraum*, der vom Hypothesenraum verschieden ist. In der Planerkennung bedeutet dies etwa, daß der Agent nicht unmittelbar den einzelnen Planhypothesen einen bestimmten Vertrauensgrad zuweisen kann, sondern vielmehr gezwungen ist, indirekt aus den beobachteten Aktionen – den Elementen des Evidenzenraumes – Rückschlüsse auf den Hypothesenraum zu ziehen. Dieser Übergang vom Evidenzen- zum Hypothesenraum entspricht im wesentlichen Dempsters mengenwertiger Abbildung aus Definition 2.1.1 sowie der *compatibility mapping* aus [Lowrance *et al.*, 1986], die den Übergang von einem Ereignisraum zu einem anderen beschreibt.²

Das nächste Kapitel wird regelbasierte Ansätze auf der Basis der Dempster-Shafer Theorie vorstellen, in denen diese Abbildung durch eine Menge sogenannter Expertenregeln realisiert wurde. Um diesen Regeln und den mit ihnen verbundenen numerischen Gewichten eine fundierte Semantik im Rahmen des bisher vorgestellten Systems geben zu können, wird das Konzept des Konditionals in die epistemische Logik aus Abschnitt 4.1.1 eingeführt.

Dazu werden im folgenden zunächst einige wichtige Eigenschaften von Konditionalen erläutert. Abschnitt 4.2 findet seine Fortsetzung mit einem Exkurs über die algebraische Charakterisierung maßfreier Konditionale in Anhang A. Dabei geht es um wichtige Eigenschaften dieser Objekte, die unter anderem bei der Definition der bedingten Wahrscheinlichkeit eine Rolle spielen und die *Ableitung* eines Konditionals aus einem anderen erlauben. Inhalt des Abschnitts 4.2.2 wird die Einführung eines syntaktischen Äquivalents zu den Konditionalen in die epistemische Logik und die konsistente Erweiterung der Theorie des evidenzbasierten Schließens sein.

Dabei wird sich herausstellen, daß eine *vollständige* Integration von Konditionalen in die zugrundeliegende Logik – d.h. als gleichwertiger Operator neben \wedge , \vee usw. – zum Verlust wichtiger algebraischer Eigenschaften führt, so daß die Ergebnisse aus den vorhergehenden Abschnitten teilweise ihre Gültigkeit verlieren. Das Sprachkonstrukt des Konditionals und die entsprechende algebraische Operation auf den möglichen Wel-

²Dieser Artikel beschreibt eine Implementierung der theoretischen Konzepte des evidenzbasierten Schließens, wobei die erwähnte Abbildung *nicht* der Kompatibilitätsrelation aus Definition 4.1.23 entspricht.

ten werden daher einen Sonderstatus innerhalb der resultierenden Sprache erhalten in dem Sinne, daß sie zwar eine konsistente Erweiterung der “herkömmlichen” Sprache darstellen, jedoch nur in einer speziellen, stark eingeschränkten Form verwendet werden.

4.2.1 Maßfreie Konditionale

Die Repräsentation einer Regel “wenn b , dann a ” geschieht üblicherweise entweder als eine *materielle Implikation* – vor allem in logischen Ansätzen – oder als *Produktionsregel* – etwa in Expertensystemen. Beide Sichtweisen sind nicht miteinander identisch, denn während eine Implikation $b \rightarrow a$ im Falle von $\neg b$ als wahr betrachtet wird, kann die entsprechende Produktionsregel überhaupt nicht angewandt werden. Ein weiterer Hinweis auf die Unterschiedlichkeit beider Konzepte ergibt sich, wenn die Regel mit einem numerischen Gewicht versehen wird, das im ersten Fall als die Wahrscheinlichkeit $P(\neg b \vee a)$, im zweiten aber als die bedingte Wahrscheinlichkeit $P(a|b)$ interpretiert wird. Es gilt nämlich:

$$P(a|b) = \frac{P(\neg b \vee a) - P(\neg b)}{1 - P(\neg b)} \neq P(\neg b \vee a).$$

Dabei kann diese bedingte Wahrscheinlichkeit auf zwei Arten gedeutet werden: Entweder steht $P(a|b)$ für “(Wahrscheinlichkeit von a) gegeben b ” oder für “Wahrscheinlichkeit von (a gegeben b).” Einerseits wäre ein solches Objekt “ a gegeben b ” die syntaktische Entsprechung einer Produktionsregel, andererseits aber existiert ein solches nicht in der Logik, und verschiedene Definitionsversuche führten zu Inkompatibilitäten mit der klassischen Definition der bedingten Wahrscheinlichkeit (siehe dazu z.B. [Harper *et al.*, 1981]).

Im folgenden werden verschiedene Ansätze zur konsistenten Definition eines Konditionals vorgestellt, die zu äquivalenten Resultaten führen. Zunächst werden einige wichtige algebraische Definitionen angegeben:

Definition 4.2.1 (Boolesche Algebra)

Eine *Boolesche Algebra* ist eine Algebra $\mathcal{B} = \langle B, \vee, \wedge, \neg, 0, 1 \rangle$ mit zwei binären Operationen \vee und \wedge , einer einstelligen Operation \neg und zwei nullstelligen Operationen 0 und 1 , so daß gilt:

1. $\langle B, \vee, \wedge \rangle$ ist ein distributiver Verband,
2. $x \wedge 0 = 0$, $x \vee 1 = 1$ und
3. $x \wedge \neg x = 0$, $x \vee \neg x = 1$.

Die bisher betrachteten Teilmengenalgebren einer Grundmenge X sind alles Beispiele für solche Booleschen Algebren, wobei \vee der Vereinigung \cup , \wedge der Durchschnittsbildung \cap , \neg der Komplementbildung sowie 0 und 1 der leeren Menge \emptyset und der Menge X selbst entsprechen.

Definition 4.2.2 (Boolescher Ring)

Ein Ring $\mathcal{R} = \langle R, +, \cdot, ', 0, 1 \rangle$ heißt *Boolescher Ring*, wenn

$$x \cdot x = x$$

für alle $x \in R$.

Daraus folgt, daß \mathcal{R} kommutativ ist und die Charakteristik 2 besitzt, d.h. $x + x = 0$ für alle $x \in R$. Jede Boolesche Algebra kann als Boolescher Ring betrachtet werden und umgekehrt:

Satz 4.2.1 (Stone)

(a) Sei $\mathcal{B} = \langle B, \vee, \wedge, \neg, 0, 1 \rangle$ eine Boolesche Algebra. Dann definiere $\mathcal{R}^{\mathcal{B}}$ als die Algebra $\langle B, +, \cdot, ', 0, 1 \rangle$, wobei

$$\begin{aligned} a + b &= (a \wedge \neg b) \vee (\neg a \wedge b) \\ a \cdot b &= a \wedge b \\ a' &= \neg a. \end{aligned}$$

Dann ist $\mathcal{R}^{\mathcal{B}}$ ein Boolescher Ring.

(b) Sei $\mathcal{R} = \langle R, +, \cdot, ', 0, 1 \rangle$ ein Boolescher Ring. Dann definiere $\mathcal{B}^{\mathcal{R}}$ als die Algebra $\langle R, \vee, \wedge, \neg, 0, 1 \rangle$, wobei

$$\begin{aligned} a \vee b &= a + b + a \cdot b \\ a \wedge b &= a \cdot b \\ \neg a &= 1 + a. \end{aligned}$$

Dann ist $\mathcal{B}^{\mathcal{R}}$ eine Boolesche Algebra.

(c) Seien \mathcal{R} und \mathcal{B} wie oben. Dann gilt: $\mathcal{R}^{\mathcal{B}^{\mathcal{R}}} = \mathcal{R}$ und $\mathcal{B}^{\mathcal{R}^{\mathcal{B}}} = \mathcal{B}$.

Bezieht man die Definition von $\mathcal{R}^{\mathcal{B}}$ wieder auf Teilmengenalgebren, so sieht man, daß $a + b$ der symmetrischen Differenz $(a \cup b) \setminus (a \cap b)$ entspricht, so daß sich die Vereinigung $a \cup b$ als $a + b + a \cdot b$ darstellen läßt.

Der folgende Satz besagt, daß Konditionale, die mit der Definition der bedingten Wahrscheinlichkeit konsistent sind, sich nicht durch Boolesche Operationen repräsentieren lassen:

Satz 4.2.2 (Lewis' Trivialitätsresultat – [Lewis, 1981]) Sei \mathcal{R} ein Boolescher Ring mit mehr als 4 Elementen. Dann gibt es keine binäre Operation \circ auf \mathcal{R} , so daß für alle Wahrscheinlichkeitsfunktionen P auf \mathcal{R} und alle $a, b \in \mathcal{R}$ mit $P(b) > 0$ gilt:

$$P(a \circ b) = P(a|b).$$

$tr(b)$	$tr(a)$	$tr(b \rightarrow a)$	$tr(a b)$
T	T	T	T
T	F	F	F
F	T	T	$?$
F	F	T	$?$

Tabelle 4.1: Materielle Implikation und Konditionierung.

$tr(b \rightarrow a)$	$tr(b)$	$tr(a)$
T	T	T
T	F	$?$
F	T	F
F	F	\times

$tr(a b)$	$tr(b)$	$tr(a)$
T	T	T
T	F	$?$
F	T	F
F	F	$?$

Tabelle 4.2: Ableitbarkeitsverhalten von \rightarrow und $|$.

Es wird daher ein neues Symbol $|$ eingeführt, das für das gesuchte Konzept des Konditionals stehen soll.

Sei von nun an eine *endliche* Boolesche Algebra \mathcal{B} gegeben, deren Elemente a, b, \dots als *Aussagen* bezeichnet werden. Dem in [Dubois und Prade, 1991] beschriebenen Ansatz folgend, werden zunächst anhand von Wahrheitstabellen notwendige Bedingungen für die exakte Definition des Konditionals hergeleitet. Dazu bezeichne $tr(x)$ den Wahrheitswert von x . Tabelle 4.1 zeigt nochmals den Unterschied zwischen materieller Implikation und Konditionierung auf, während Tabelle 4.2 das Ableitbarkeitsverhalten beider Konzepte miteinander vergleicht. Ein Eintrag “?” steht dabei für einen unbestimmten Wahrheitswert.

Der Eintrag \times in Tabelle 4.2 verweist auf eine unmögliche Situation, denn wenn $tr(b) = F$ gilt, so ist die Implikation auf jeden Fall erfüllt, d.h. es gilt $tr(b \rightarrow a) = T$. Der Wert $tr(a|b)$ kann auch implizit definiert werden durch

$$tr(a \wedge b) = tr(a|b) * tr(b), \quad (4.20)$$

wobei $T * T = T$ und $T * F = F * T = F * F = F$ die Verknüpfung der Wahrheitswerte ist:

1. Ist $tr(a) = tr(b) = T$, so folgt aus (4.20), daß $tr(a|b) = T$.
2. Ist $tr(a) = F$, $tr(b) = T$, so ist $tr(a|b) = F$.
3. Ist $tr(b) = F$, so sind sowohl $tr(a|b) = T$, als auch $tr(a|b) = F$ mit (4.20) kompatibel.

Somit gilt, daß jede Aussage x mit $tr(a \wedge b) = tr(x) * tr(b)$ für $a|b$ stehen kann. Eine exakte algebraische Charakterisierung maßfreier Konditionale findet sich in Anhang A.

4.2.2 Integration von Konditionalen in die epistemische Logik

Alle in Anhang A präsentierten Lösungen von (4.20) werden von nun ab mit $a|b$ bezeichnet. Gegeben sei wiederum die Boolesche Algebra $\mathcal{R} = \langle R, \vee, \wedge, \neg, 0, 1 \rangle$ bzw. der entsprechende Boolesche Ring. Ist eine Wissensbasis $K \subseteq \mathcal{R}|\mathcal{R}$ gegeben, so stellt der Anteil $F_K = K \cap \mathcal{R}$ die Menge der *Fakten* dar, während $R_K = K \cap \mathcal{R}|\mathcal{R} \setminus \mathcal{R}$ der *Regelbasis* entspricht.

Im folgenden werden die algebraischen Eigenschaften von $\mathcal{R}|\mathcal{R}$ untersucht, indem die Operatoren von \mathcal{R} auf $\mathcal{R}|\mathcal{R}$ verallgemeinert werden. Es existieren unterschiedliche Ansichten darüber, wie diese Verallgemeinerungen definiert werden sollen. Die wichtigsten davon werden im folgenden kurz diskutiert.

Der in [Nguyen und Rogers, 1991] vertretene Ansatz beruht darauf, die Operationen auf den Äquivalenzklassen für einen festen Antezedenten wie etwa $(a|b) + (c|b) = (a + c|b)$ für den Fall verschiedener Antezedenten zu verallgemeinern. Schreibt man diese Gleichung nämlich in der Form

$$(a|b) + (c|b) = \{x + y | x \in (a|b), y \in (c|b)\},$$

(und analog für \cdot), so liegt folgende Definition nahe:

$$(a|b) + (c|d) = \{x + y | x \in (a|b), y \in (c|d)\}.$$

Die so definierten Operationen sind auf $\mathcal{R}|\mathcal{R}$ abgeschlossen und können folgendermaßen explizit angegeben werden:

$$(a|b) + (c|d) = (a + c|bd) \tag{4.21}$$

$$(a|b) \cdot (c|d) = (ac|a'b \vee c'd \vee bd) \tag{4.22}$$

$$(a|b) \vee (c|d) = (a \vee c|ab \vee cd \vee bd) \tag{4.23}$$

Anmerkungen:

1. $\mathcal{R}|\mathcal{R}$ ist mit diesen Operationen kein Ring mehr, da es keine additiven Inversen gibt. Die Negation kann nämlich nur als $(a|b)' = (a'|b)$ definiert werden (fixiere dazu ein b und betrachte die entsprechende Operation auf den Äquivalenzklassen in \mathcal{S}_b). Dann gilt zwar $(a|b) + (a|b)' = (0|b) = 0_b$ für alle $a, b \in \mathcal{R}$, aber 0_b ist *nicht* die Null von $\mathcal{R}|\mathcal{R}$.
2. Führt man statt dieser Negation das sogenannte “Pseudokomplement” ein, so ergibt sich für $\mathcal{R}|\mathcal{R}$ die Struktur einer *Stone Algebra*. Ein Pseudokomplement a^* eines Elementes a ist charakterisiert durch $a \wedge a^* = 0$ und für alle x : wenn

$a \wedge x = 0$, so folgt $x \leq a^*$. Eine Stone Algebra ist dann ein distributiver Verband mit Pseudokomplement, der die *Stone Identität* $a^* \vee a^{**} = 1$ erfüllt. Im konkreten Fall von $\mathcal{R}|\mathcal{R}$ ist das Pseudokomplement von $(a|b)$ gegeben durch $(a'b|1)$ (siehe dazu [Nguyen, 1992]). Für eine detaillierte Beschreibung von Stone Algebren sei auf [Grätzer, 1978] verwiesen.

Doch auch andere Definitionsvorschläge für die Konnektoren zwischen konditionalen Ereignissen führen nicht zur Erhaltung der Struktur einer Booleschen Algebra. In [Calabrese, 1987] wird beispielsweise die Konjunktion definiert als

$$(a|b) \wedge_1 (c|d) = ((b \rightarrow a) \wedge (d \rightarrow c)|b \vee d). \quad (4.24)$$

Leitet man daraus gemäß den Gesetzen von De Morgan die Disjunktion \vee_1 ab, so sind diese Operationen nicht distributiv untereinander, so daß auch hier der Raum der bedingten Ereignisse keine Boolesche Algebra mehr darstellt.

Dennoch ist diese Verknüpfung in Hinsicht auf regelbasierte Systeme natürlicher als die in (4.22) eingeführte. Betrachtet man nämlich die durch $(a|b)$ und $(c|d)$ gebildete Regelbasis, so liegt es nahe, diese immer dann als anwendbar zu definieren, wenn mindestens eine der Regeln anwendbar ist, also wenn $b \vee d$ gilt. Im Gegensatz dazu ist die Anwendbarkeitsbedingung im Fall (4.22), daß entweder beide Regeln anwendbar sind oder – für den Fall, daß nur eine anwendbar ist – daß deren Konklusion falsch ist. Die Konjunktion \wedge_1 kann unter Berücksichtigung der Wahrheitswerte T , F und $?$ motiviert werden durch die Wahl

$$T \wedge_1 ? = T, F \wedge_1 ? = F, ? \wedge_1 ? = ?,$$

während (4.22) auf


$$T \wedge ? = ?, F \wedge ? = F, ? \wedge ? = ?$$

beruht. Die Verknüpfung \wedge_1 wird im folgenden bei der Betrachtung der Konditionale als Regeln eine Rolle spielen.

Um Inferenzen mit Konditionalen durchführen zu können, muß eine (partielle) Ordnungsrelation auf $\mathcal{R}|\mathcal{R}$ eingeführt werden. Analog zur Definition in Booleschen Algebren sei

$$(a|b) \leq (c|d) :\iff (a|b) \cdot (c|d) = (a|b). \quad (4.25)$$

Dies ist genau dann der Fall, wenn $ab \leq cd$ und $c'd \leq a'b$ gilt, wenn also jedes *positive* Beispiel ab für die "Regel" $(a|b)$ auch ein Beispiel für $(c|d)$ und jedes *Gegenbeispiel* $c'd$ für $(c|d)$ auch eines für $(a|b)$ ist. Stellt man die entsprechenden konditionalen Objekte als Intervalle dar, wobei die Ordnungsrelation auf \mathcal{R} von links nach rechts ansteigt, so ergeben sich folgende Möglichkeiten für den Fall $(a|b) \leq (c|d)$:



oder

$$\begin{array}{ccc} \overline{a \wedge b} & & \overline{-b \vee a} \\ & & \\ & & \overline{c \wedge d} \\ & & \overline{-d \vee c} \end{array}$$

Diese Ordnung ist mit Wahrscheinlichkeiten verträglich, denn wenn $(a|b) \leq (c|d)$, so gilt auch für die bedingte Wahrscheinlichkeit $P(a|b) \leq P(c|d)$ für alle Wahrscheinlichkeitsverteilungen P . Außerdem ist sie offensichtlich mit der Ordnung auf $\mathcal{R} \cong \mathcal{R}|1$ kompatibel.

Der Konditionaloperator $|\cdot|$ ist im zweiten Argument *nichtmonoton*, was sich unter anderem darin äußert, daß $(a|b)$ und $(a|b \wedge c)$ bzgl. \leq nicht miteinander vergleichbar sind. Dieser Punkt wird bei der Betrachtung regelbasierter Systeme eine Rolle spielen.

Es bleibt somit zu klären, wie Konditionale $(a|b)$ mit $b \neq 1$ (bzw. \top auf der logischen Seite) in die epistemische Logik aus Abschnitt 4.1.1 integriert werden können. Wie obige Diskussion gezeigt hat, führt die vollständige Erweiterung des Satzraumes \mathcal{S} zu $\mathcal{S}|\mathcal{S}$ mit den entsprechenden logischen Operationen gemäß (4.22) und (4.23) bzw. (4.24) zum Verlust wichtiger struktureller Eigenschaften bei den in Abschnitt 4.1.3 eingeführten Algebren Ω_E und Ω_T der möglichen Welten. Der in der hier vorliegenden Arbeit verfolgte Ansatz beruht daher auf einer Einschränkung der logischen Operationen auf bestimmte Sonderfälle. Dies vermeidet einerseits die oben angesprochenen Probleme, läßt die sich ergebende Sprache jedoch ausdrucksstark genug, um alle wichtigen Verknüpfungen für ein regelbasiertes System vornehmen zu können.

Die Menge aller möglichen Formeln wird dazu zweigeteilt in die Menge der *Fakten* und die der Konditionale oder *Regeln*. Während auf den Fakten alle logischen Operationen aus \mathcal{S} zulässig sind, ist die Verknüpfung von Fakten und Regeln miteinander auf einen Fall beschränkt, die zu definierende *Regelanwendung*. Regeln dürfen untereinander nicht verknüpft werden. Zunächst wird aufgezeigt, wie sich die wesentlichen Definitionen für \mathcal{S} konsistent auf diesen Fall erweitern lassen, bevor das prinzipielle Aussehen und die Anwendung einer Wissensbasis beschrieben werden.

Definition 4.2.3 (erweiterter Satzraum)

Der *erweiterte Satzraum* \mathcal{S}^+ ist wie folgt definiert:

Jede Formel aus \mathcal{S} ist auch Element von \mathcal{S}^+ .

Sind $\alpha, \beta \in \mathcal{S}^+$, so ist auch $(\alpha|\beta) \in \mathcal{S}^+$.

Sind $\beta \in \mathcal{S}$ und $(\alpha|\beta) \in \mathcal{S}^+$, so ist auch $\beta \wedge (\alpha|\beta) \in \mathcal{S}^+$.

\mathcal{S}^+ stellt somit gerade die Erweiterung von \mathcal{S} aus Definition 4.1.1 um die Konditionale oder *Regeln* $\alpha|\beta$ dar. Der Konditionaloperator $|\cdot|$ kann dabei auch geschachtelt auftreten, d.h. $((\alpha|\beta)|\gamma)$ ist eine syntaktisch zulässige Formel aus \mathcal{S}^+ . Demgegenüber sind Verknüpfungen wie $\alpha \vee (\beta|\gamma)$ *nicht* zulässig. Lediglich die konjunktive Verknüpfung

eines Konditionals mit seiner Prämisse gemäß Gleichung (4.24), die wiederum einer Formel aus \mathcal{S} entspricht, ist erlaubt (zu den algebraischen Konsequenzen dieser Einschränkungen siehe auch die Anmerkungen auf Seite 74). D.h. die konjunktive Verknüpfung entspricht dem Operator \wedge_1 . Die “echten” Konditionale $\alpha|\beta$ mit $\beta \not\Leftarrow \top$ erhalten somit einen Sonderstatus bzgl. ihrer syntaktischen Verwendung.

Erweitert man die Definition 4.1.4 der logischen Äquivalenz \Leftrightarrow für den Fall von Konditionalen, so läßt sich auf der Basis von \mathcal{S}^+ der erweiterte Ereignisraum definieren.

Definition 4.2.4 (logische Äquivalenz)

Zwei Formeln $\alpha, \beta \in \mathcal{S}^+$ heißen genau dann *logisch äquivalent*, wenn $\alpha \leq \beta$ und $\beta \leq \alpha$, wobei die Relation \leq durch (4.25) gegeben ist. Dies wird mit $\alpha \Leftrightarrow \beta$ bezeichnet.

Definition 4.2.5 (erweiterter Ereignisraum)

Der Quotientenraum $Obj(\mathcal{S}^+)/\Leftrightarrow$ der objektiven Formeln modulo dieser logischen Äquivalenz heißt (*erweiterter*) *Ereignisraum* und wird mit $\Phi(\mathcal{S}^+)$ bezeichnet.

Entsprechend muß der Begriff der Interpretation auf \mathcal{S}^+ erweitert werden:

Definition 4.2.6 (Interpretation)

Eine *Interpretation* für \mathcal{S}^+ ist eine Abbildung $\mathcal{W} : \mathcal{S}^+ \rightarrow \{T, F\}$. Eine Formel $\alpha|\beta \in \mathcal{S}^+ \setminus \mathcal{S}$ heißt *anwendbar in \mathcal{W}* , falls $\mathcal{W}(\beta) = T$ und *wahr in \mathcal{W}* , falls $\mathcal{W}(\alpha) = \mathcal{W}(\beta) = T$. Wahrheit für Formeln aus $\mathcal{S} \subset \mathcal{S}^+$ wird wie bisher definiert.

Definition 4.2.7 (mögliche Welten, Universum)

Die Menge der möglichen Welten für den erweiterten Satzraum \mathcal{S}^+ ist die Menge aller Interpretationen für \mathcal{S}^+ , die die Axiomenschemata **(M1)** – **(M5)** aus Definition 4.1.3 erfüllen. Die Menge aller möglichen Welten für \mathcal{S}^+ heißt das *Universum* und wird mit $\mathcal{U}(\mathcal{S}^+)$ bezeichnet.

Notation: Die Menge aller Welten \mathcal{W} , in denen $\alpha|\beta$ anwendbar ist, heißt *der Anwendbarkeitsbereich von $\alpha|\beta$* und wird mit $\mathbf{a}(\alpha|\beta)$ bezeichnet.

Die Definition 4.1.16 der Erfüllungsmenge kann nun *nicht* analog erweitert werden zu

$$\mathbf{T}(\alpha) = \{\mathcal{W} \mid \alpha \in \mathcal{S}^+, \alpha \text{ wahr in } \mathcal{W}\}. \quad (4.26)$$

In diesem Fall wäre nämlich

$$P((\alpha|\beta)) = P(\mathbf{T}(\alpha|\beta)) = P(\alpha \wedge \beta) \neq P(\alpha|\beta).$$

Gemäß (4.26) definiert, wäre **T** das mengentheoretische Äquivalent des der Konditionierung $|\cdot|$ entsprechenden Booleschen Operators, der nach Lewis' Trivialitätsresultat nicht existiert (vgl. Satz 4.2.2). Vielmehr ist folgende Definition der Wahrscheinlichkeit einer Formel aus \mathcal{S}^+ in Ergänzung zu (4.14) anzuwenden: Für alle $\alpha|\beta \in \mathcal{S}^+$ gilt

$$P((\alpha|\beta)) := \frac{P(\mathbf{T}(\alpha \wedge \beta))}{P(\mathbf{a}(\alpha|\beta))} = \frac{P(\alpha \wedge \beta)}{P(\beta)}. \quad (4.27)$$

Die Konsistenz dieser Erweiterung mit (4.14) ist wie folgt einzusehen, wobei Formeln $\alpha \in \mathcal{S} \subset \mathcal{S}^+$ mit Konditionalen $\alpha|\top$ identifiziert werden:

$$\begin{aligned}
P((\alpha|\top)) &= \frac{P(\mathbf{T}(\alpha \wedge \top))}{P(\mathbf{a}(\alpha|\top))} && \text{nach (4.27)} \\
&= \frac{P(\mathbf{T}(\alpha))}{P(\mathbf{T}(\top))} \\
&= P(\mathbf{T}(\alpha)) \\
&= P(\alpha) && \text{nach (4.14)}.
\end{aligned}$$

Eine Regel $\alpha|\beta$ sollte immer dann angewandt werden, wenn ihre Prämisse β erfüllt ist. Als Ergebnis dieser Regelanwendung wird die Ableitung der entsprechenden Konklusion α erwartet. Bezogen auf eine spezifische mögliche Welt \mathcal{W} bedeutet dies, daß die Anwendung dieser Regel möglich ist, wenn $\mathcal{W} \in \mathbf{a}(\alpha|\beta) = \mathbf{T}(\beta)$ gilt und das erwartete Resultat produziert, wenn $\alpha|\beta$ wahr in \mathcal{W} ist, d.h. wenn $\mathcal{W} \in \mathbf{T}(\alpha \wedge \beta)$. Dies läßt sich durch folgende Definition formalisieren:

Definition 4.2.8 (Regelanwendung)

Für $\beta \in \mathcal{S} \subset \mathcal{S}^+$ und $\alpha|\beta \in \mathcal{S}^+ \setminus \mathcal{S}$ wird der Ausdruck

$$appl(\alpha|\beta) = \beta \wedge_1 (\alpha|\beta)$$

als die *Anwendung* oder das *Feuern* der Regel $\alpha|\beta$ durch β bezeichnet.

Anmerkung: Da im folgenden nur noch diese konjunktive Verknüpfung \wedge_1 zur Anwendung kommt, wird der Einfachheit halber von nun an das Symbol \wedge verwendet.

Gemäß (4.24) ist dies äquivalent zu

$$\begin{aligned}
(\beta|\top) \wedge_1 (\alpha|\beta) &= ((\top \rightarrow \beta) \wedge (\beta \rightarrow \alpha)|\top \vee \beta) \\
&= (\beta \wedge (\beta \rightarrow \alpha)|\top) \\
&= \beta \wedge (\beta \rightarrow \alpha).
\end{aligned}$$

Somit konstituiert die Anwendung einer Regel einen logischen Beweis für ihre Konklusion, denn

$$\beta \wedge (\beta \rightarrow \alpha) \Rightarrow \alpha.$$

Dies entspricht auch der Charakterisierung des Konditionaloperators $|\cdot|$ in [Dubois und Prade, 1991, S. 126] als ein dem Ableitungsoperator \vdash verwandtes Konzept, so daß die bedingte Wahrscheinlichkeit $P(\alpha|\beta)$ die Wahrscheinlichkeit der Existenz eines Beweises (einer Ableitung) von α aus β beschreibt.

Anmerkungen:

1. Die mit der Konjunktion $\beta \wedge_1 (\alpha|\beta)$ korrespondierende algebraische Operation auf den Algebren über $\mathcal{U}(\mathcal{S}^+)$ läßt sich als aus den herkömmlichen Algebraoperationen abgeleiteten Operator darstellen. Es wird daher etwa in die epistemischen Algebren Ω_E keine Operation eingeführt, die den Durchschnittsoperator \cap für den Fall von Intervallen ergänzt oder gänzlich ersetzt, wie dies bei einer *vollständigen* Integration der Konditionale und dem daraus folgenden Übergang zum Sprachraum $\mathcal{S}_K|\mathcal{S}_K$ notwendig gewesen wäre. Somit bleiben die grundlegenden Eigenschaften der in Abschnitt 4.1 eingeführten Algebren erhalten. Eine Algebra Ω über $\mathcal{U}(\mathcal{S})$ ist daher identisch mit der entsprechenden Algebra über $\mathcal{U}(\mathcal{S}^+)$ mit der Ausnahme, daß in letzterer der einer Regelanwendung entsprechende abgeleitete Operator zur Verfügung steht.
2. Für ein Konditional $x = \alpha|\beta$ bezeichnet seine Wahrscheinlichkeit die relative Wahrscheinlichkeit der Menge der x gemäß Definition 4.2.6 wahr machenden Welten bzgl. seines Anwendbarkeitsbereiches. Im Vergleich dazu ist die Wahrscheinlichkeit einer Formel $\alpha \in \mathcal{S}$ das absolute Maß der Wahrscheinlichkeit ihrer Erfüllungsmenge bzw. – äquivalent dazu – die Relativierung dieser Wahrscheinlichkeit bzgl. des Universums $\mathcal{U}(\mathcal{S}^+)$.
3. In Anwendungen, wie sie im nächsten Kapitel beschrieben werden, sind mit einer Wissensbasis K oft auch marginale und bedingte Wahrscheinlichkeiten angegeben. Diese werden mit den Wahrscheinlichkeiten der entsprechenden die Formel wahr machenden Welten identifiziert und stellen Randbedingungen für die Menge der möglichen Welten dar in dem Sinne, daß die Wahrscheinlichkeiten von Welten mit bestimmten Eigenschaften in gewissen, durch diese Wahrscheinlichkeiten bestimmten, Relationen zueinander stehen. Die numerische Gewichtung einer sogenannten “Expertenregel” $\beta \rightarrow \alpha$ (bzw. $\alpha|\beta$), repräsentiert durch die bedingte Wahrscheinlichkeit $P(\alpha|\beta)$, stellt dort den einer Hypothese α zuzuordnenden Vertrauensgrad dar, wenn die Evidenz β gegeben ist. Dieser entspricht gerade der Wahrscheinlichkeit von α in der Menge der durch diese Evidenz identifizierten möglichen Welten.

4.2.3 Zusammenfassung

Neben der Vorstellung von Ruspinis Theorie des evidenzbasierten Schließens, die die Charakterisierung der Dempster-Shafer Theorie auf der Basis einer epistemischen Modallogik erlaubt, bestand die wesentliche Leistung dieses Kapitels in der Integration von *Konditionalen* als syntaktischer Entsprechung von *Expertenregeln* in diese Logik. Die Untersuchung der verschiedenen alternativen Ansätze aus der Literatur ergab dabei, daß die Forderung nach der Verträglichkeit dieser Operatoren mit der Wahrscheinlichkeitstheorie deren Einbettung in die Logik teilweise einschränkt.

Als Resultat ergibt sich somit eine epistemische Modallogik, die folgende Ausdrucksmittel zur Repräsentation unterschiedlicher Aspekte von Information zur Verfügung stellt.

- *objektive Formeln* ohne Modalitäten zur Kennzeichnung tatsächlicher Sachverhalte,
- die *Modaloperatoren* \mathbf{K} und \mathbf{K}_e , die das *Wissen* bzw. “*exakte*” *Wissen* (siehe (4.3)) eines Agenten repräsentieren,
- die üblichen *logischen Konnektoren* \wedge, \vee, \neg und \rightarrow zur Verknüpfung der bisher aufgezählten Klassen von Formeln,
- den *Konditionaloperator* $\cdot|$ sowie
- die *Regelanwendung* (siehe Definition 4.2.8) $\text{appl}(\alpha|\beta)$, die ein Konditional mit seiner Prämisse verknüpft und somit das “Feuern” einer Regel bei Eintreten ihrer Prämisse repräsentiert.

Der dermaßen erweiterte Satzraum \mathcal{S}^+ wird in den folgenden Kapiteln die Grundlage für die Untersuchung verschiedener regelbasierter Ansätze aus dem Bereich der Expertensysteme, die Angabe einer wahrscheinlichkeitstheoretischen Semantik für die dabei verwendete Erweiterung der Dempster-Shafer Theorie sowie die Entwicklung eines evidenztheoretischen Ansatzes zur Planerkennung bilden.

Kapitel 5

Regelbasierte Ansätze auf der Basis der Dempster-Shafer Theorie

Während das vorangehende Kapitel die modallogische Fundierung des evidenzbasierten Schließens untersuchte und erweiterte, wird dieses Kapitel den zweiten Teil der Grundlage des zu entwickelnden Ansatzes zur Planerkennung behandeln. Dabei handelt es sich um regelbasierte Systeme aus dem Bereich der Expertensysteme, die Methoden aus der Dempster-Shafer Theorie benutzen, um Unsicherheit in evidenzbasierten Schlüssen zu repräsentieren.

Die Motivation zur Verwendung dieses Formalismus in den beiden hier vorgestellten Ansätzen bestand dabei in der Beobachtung, daß Evidenzen oft nicht aussagekräftig genug sind, um die elementaren Bestandteile einer abstrakten Hypothese einzeln bewerten zu können, wie etwa die einzelnen Elemente einer Menge von Alternativen oder die einzelnen Glieder einer Disjunktion von Hypothesen. In [Yen, 1986] findet sich dazu folgendes Beispiel: Ein bestimmtes Symptom kann z.B. auf rheumatische Arthritis hindeuten. Diese (abstrakte) Krankheitsbeschreibung umfaßt ihrerseits wieder die beiden Konzepte der seropositiven sowie seronegativen rheumatischen Arthritis. Das beobachtete Symptom gibt jedoch keinerlei Hinweise, um welche dieser beiden konkreten Ausformungen es sich im vorliegenden Fall handelt.

Die Schlußfolgerung daraus ist, daß eine Repräsentation von Unwissenheit (Ignoranz) eine wesentliche Rolle bei der Modellierung von Evidenz hinsichtlich *Gruppen* von Hypothesen spielt. Die klassische Wahrscheinlichkeitstheorie ist dabei i.a. zu präzise, da sie immer eine Bewertung der Einzelhypothesen liefert (eine diskrete Wahrscheinlichkeitsverteilung). Andererseits stellt die Dempster-Shafer Theorie, bei der dieses Problem nicht besteht, keinen Mechanismus zur Repräsentation einer *unsicheren* Beziehung zwischen Evidenz und Hypothese zur Verfügung. Vielmehr kann die Beziehung zwischen beiden als eine Art ("sicherer") Implikation interpretiert werden, wie die Diskussion zu Beginn von Abschnitt 5.1 zeigen wird.

Von diesen Prämissen ausgehend entwickelte Yen den in [1986] und [1989] be-

schriebenen Ansatz, der im Expertensystem Gertis realisiert und von Guan und Bell in [1991] verallgemeinert wurde. Die nachfolgenden Abschnitte beschreiben die Grundlagen dieser Arbeiten. Während Yen die Übereinstimmung seines Ansatzes mit der Wahrscheinlichkeitstheorie demonstriert und damit prinzipiell auch eine Semantik für diesen Mechanismus angibt, wird dies für den verallgemeinerten Fall nicht getan. Aus diesem Grund wird in Abschnitt 5.3 erstmals eine auf den im vorigen Kapitel beschriebenen Konzepten basierende Semantik für das System von Guan und Bell entwickelt, bevor in 5.4 die Stärken und Schwächen der vorgestellten Systeme analysiert werden.

5.1 Eine Erweiterung der Dempster-Shafer Theorie

Grundlage für die Ausführungen dieses Abschnittes bilden die Arbeiten [Yen, 1986] und [Yen, 1989]. Im folgenden bezeichne $\Theta \neq \emptyset$ den *Evidenzenraum*, $\Omega \neq \emptyset$ den *Ereignisraum* oder *Hypothesenraum* und $\Gamma : \Theta \rightarrow 2^\Omega$ die mengenwertige Abbildung gemäß Definition 2.1.1. Der Ansatzpunkt für Yens Arbeit besteht in der Beobachtung, daß eine Gleichung

$$\Gamma(e) = H$$

mit $e \in \Theta$ und $H \subseteq \Omega$, die in der Dempster-Shafer Theorie eine (qualitative) Verbindung zwischen einer Evidenz e und einer Hypothesenmenge H repräsentiert, sich auch in Form einer bedingten Wahrscheinlichkeit über dem erweiterten Raum $\Theta \times \Omega$ darstellen läßt:¹

$$P(H|e) = 1 \text{ und } P(\overline{H}|e) = 0.$$

Läßt man diese bedingte Wahrscheinlichkeit auch Werte *innerhalb* des Intervalls $[0, 1]$ anstelle der Extreme 0 und 1 annehmen, so ist es möglich, *unsichere* Verbindungen zwischen Evidenzen und Hypothesen zu repräsentieren. Zu diesem Zweck wird die Funktion Γ verallgemeinert zu:

Definition 5.1.1 (probabilistische Beobachtungsfunktion)

Seien Θ und Ω wie oben. Dann ist $\Gamma^* : \Theta \rightarrow 2^{2^\Omega \times [0,1]}$ mit

$$e \mapsto \{\langle H_{e,1}, P(H_{e,1}|e) \rangle, \dots, \langle H_{e,l}, P(H_{e,l}|e) \rangle\}$$

- mit
1. $H_{e,i} \neq \emptyset$ für alle $e \in \Theta$, $1 \leq i \leq l$
 2. $H_{e,i} \cap H_{e,j} = \emptyset$ für alle $i \neq j$
 3. $P(H_{e,i}|e) > 0$ für alle $1 \leq i \leq l$
 4. $\sum_{i=1}^l P(H_{e,i}|e) = 1$

eine *probabilistische Beobachtungsfunktion*.

¹Hier und im folgenden werden oft einelementige Mengen $\{e\}$ und die einzelnen Elemente e miteinander identifiziert, so daß $P(H|e)$ als Kurzform für $P(H|\{e\})$ dient.

Beispiel 5.1.1 Gegeben sei eine Expertenregel

if e_1	then	$\{h_1, h_2\}$	with	0.8
		$\{h_3, h_4\}$	with	0.2
else if e_2	then	$\{h_2, h_4\}$	with	0.3
		$\{h_1, h_5\}$	with	0.7
	\vdots			

Diese entspricht im obigen Kontext einer Abbildung mit

$$\begin{aligned}\Gamma^*(e_1) &= \{\langle\{h_1, h_2\}, 0.8\rangle, \langle\{h_3, h_4\}, 0.2\rangle\} \\ \Gamma^*(e_2) &= \{\langle\{h_2, h_4\}, 0.3\rangle, \langle\{h_1, h_5\}, 0.7\rangle\}\end{aligned}$$

usw.

Definition 5.1.2 (assoziierte Hypothesenmenge)

Sei $\Gamma^*(e) = \{\langle H_1, P(H_1|e)\rangle, \dots, \langle H_l, P(H_l|e)\rangle\}$. Dann heißt

$$G_{\Gamma^*}(e) = \{H_1, \dots, H_l\}$$

die mit e assoziierte Hypothesenmenge (eig. ‘‘Körnchenmenge’’, granule set). Wenn keine Verwechslung möglich ist, wird im folgenden meist der Index Γ^* weggelassen.

Eine solche Abbildung Γ^* repräsentiert somit unvollständiges Wissen über die bedingten Wahrscheinlichkeiten im Raum $\Theta \times \Omega$, wobei die Unvollständigkeit von der Tatsache herrührt, daß i.a. nur die numerischen Werte für *bestimmte* Mengen von Hypothesen bekannt sind.

Definition 5.1.3 (Regelstärke)

Die Funktion $s_e : 2^\Omega \rightarrow [0, 1]$ mit

$$s_e(H) = \begin{cases} P(H|e), & \text{falls } H \in G_{\Gamma^*}(e) \\ 0, & \text{sonst} \end{cases}$$

heißt die mit e durch Γ^* assoziierte Regelstärke.

Lemma 5.1.1 Die Abbildung s_e aus Definition 5.1.3 ist eine Basiswahrscheinlichkeit.

Beweis: Sei $e \in \Theta$ beliebig.

1. $\emptyset \notin G(e)$ nach Definition 5.1.1, 1. und somit $s_e(\emptyset) = 0$ gemäß Definition 5.1.3

$$\begin{aligned}2. \sum_{H \subseteq \Omega} s_e(H) &= \sum_{\substack{H \subseteq \Omega \\ H \in G(e)}} s_e(H) + \underbrace{\sum_{\substack{H \subseteq \Omega \\ H \notin G(e)}} s_e(H)}_{=0} \\ &= \sum_{\substack{H \subseteq \Omega \\ H \in G(e)}} P(H|e)\end{aligned}$$

= 1 nach Definition 5.1.1, 4. □

Es bleibt nun zu beschreiben, wie die einer solchen Abbildung Γ^* entsprechenden Expertenregeln im Falle einer konkreten Evidenz angewandt werden, um eine Bewertung des Hypothesenraumes zu erhalten. Sei \mathcal{E} eine Evidenz, die zu einer bedingten Wahrscheinlichkeitsverteilung auf dem Evidenzenraum Θ führt.² D.h. es steht Information \mathcal{E} zur Verfügung, die es erlaubt, dem Auftreten der Elemente $e \in \Theta$ gewisse Vertrauensgrade $P(e|\mathcal{E})$ zuzuordnen. Diese bedingte Wahrscheinlichkeit repräsentiert somit eine Evidenz, die selbst wieder mit einem Unsicherheitsgrad versehen ist. Gilt $P(e_0|\mathcal{E}) = 1$ und $P(e|\mathcal{E}) = 0$ für alle $e \neq e_0$, so liegt eine *sichere* Evidenz vor, die als Spezialfall durch den beschriebenen Ansatz abgedeckt wird.

Definition 5.1.4 (induzierte Hypothesenstärke)

In dieser Situation heißt die Abbildung

$$\begin{aligned} m(\cdot|\mathcal{E}) : 2^\Omega &\rightarrow [0, 1] \\ H &\mapsto \sum_{e: H \in G_{\Gamma^*}(e)} P(H|e) P(e|\mathcal{E}) \end{aligned}$$

die durch Γ^* und \mathcal{E} induzierte Hypothesenstärke. Im folgenden wird meist statt $m(H|\mathcal{E})$ einfach $m(H)$ geschrieben.

Anmerkungen:

1. Eine wesentliche Voraussetzung für die Berechnung von $m(\cdot|\mathcal{E})$ ist die Existenz einer diskreten Wahrscheinlichkeitsverteilung $P(\cdot|\mathcal{E})$ auf dem Evidenzenraum, d.h. das Hintergrundwissen \mathcal{E} der Evidenz – etwa ein Experiment oder eine Messung – muß spezifisch genug sein, um jede elementare Evidenz $e \in \Theta$ bewerten zu können.
2. Beschränkt man sich in obiger Definition auf die Werte 0 und 1 für $P(H|e)$, so erhält man die Grundgleichung aus der Definition der Massenverteilung (siehe Definition 2.1.1).
3. m ist eine Basiswahrscheinlichkeit.
4. m läßt sich äquivalent mit Hilfe der Regelstärke darstellen:

$$m(H) = \sum_{e \in \Theta} s_e(H) P(e|\mathcal{E}) \quad (5.1)$$

Lemma 5.1.2 *Unter der bedingten Unabhängigkeitsannahme*

$$P(H'|e, \mathcal{E}) = P(H'|e)$$

² \mathcal{E} steht für die eigentliche Beobachtung oder Messung, die nicht im Rahmen von Evidenzen- und Hypothesenraum formalisiert ist. Sie bezeichnet somit die initiale Information im Ablauf von Beobachtung und Bewertung.

für alle $H' \subseteq \Omega$ und $e \in \Theta$ gilt für alle $H \subseteq \Omega$:

$$Bel_m(H) \leq P(H|\mathcal{E}) \leq Pl_m(H), \quad (5.2)$$

d.h. die mit der Hypothesenstärke assoziierten Belief- und Plausibilitätsfunktionen bilden die unteren und oberen Wahrscheinlichkeitsschranken für den Hypothesenraum.

Zum Beweis sei auf [Yen, 1986], Appendix, Beweis von Lemma 1, verwiesen.

Im Rahmen dieses Modells, dessen Kern durch Definition 5.1.4 und Gleichung (5.1) beschrieben wird, treten jedoch Probleme bei der Verwendung von Dempsters Regel zur Kombination von Basiswahrscheinlichkeiten auf, wie das folgende Beispiel aus [Yen, 1986] zeigt:

Beispiel 5.1.2 Seien $\{e_1, \bar{e}_1\}$, $\{e_2, \bar{e}_2\}$ zwei Evidenzräume für einen gemeinsamen Hypothesenraum Ω mit den Regeln

$$\begin{array}{llll} \text{if } e_1 & \text{then } H & \text{with } P(H|e_1) & \text{if } e_2 & \text{then } H & \text{with } P(H|e_2) \\ & \bar{H} & \text{with } P(\bar{H}|e_1) & & \bar{H} & \text{with } P(\bar{H}|e_2) \\ & \text{else } \Omega & \text{with } 1.0 & & \text{else } \Omega & \text{with } 1.0 \end{array}$$

Ferner seien sowohl e_1 als auch e_2 mit Sicherheit beobachtet worden, d.h. $P(e_1|\mathcal{E}_1) = P(e_2|\mathcal{E}_2) = 1$. Gemäß Definition 5.1.4 werden somit Hypothesenstärken m_1 und m_2 induziert mit

$$\begin{aligned} m_1(H|\mathcal{E}_1) &= m_1(H) = P(H|e_1) \\ m_1(\bar{H}|\mathcal{E}_1) &= m_1(\bar{H}) = P(\bar{H}|e_1) \\ m_2(H|\mathcal{E}_2) &= m_2(H) = P(H|e_2) \\ m_2(\bar{H}|\mathcal{E}_2) &= m_2(\bar{H}) = P(\bar{H}|e_2) \end{aligned}$$

Dempsters Regel ergibt

$$m_{12}(H) = (m_1 \oplus m_2)(H) = \frac{P(H|\mathcal{E}_1) P(H|\mathcal{E}_2)}{P(H|\mathcal{E}_1) P(H|\mathcal{E}_2) + P(\bar{H}|\mathcal{E}_1) P(\bar{H}|\mathcal{E}_2)} \quad (5.3)$$

sowie

$$m_{12}(\bar{H}) = (m_1 \oplus m_2)(\bar{H}) = \frac{P(\bar{H}|\mathcal{E}_1) P(\bar{H}|\mathcal{E}_2)}{P(H|\mathcal{E}_1) P(H|\mathcal{E}_2) + P(\bar{H}|\mathcal{E}_1) P(\bar{H}|\mathcal{E}_2)} \quad (5.4)$$

Es gilt: $Bel_{m_{12}}(H) = Pl_{m_{12}}(H) = m_{12}(H)$. Da in diesem Fall die untere und obere Wahrscheinlichkeitsschranke zusammenfallen, müssen diese identisch mit der Wahrscheinlichkeit selbst sein. Außerdem ist hier die Konditionierung bzgl. der Hintergrundinformation \mathcal{E}_1 und \mathcal{E}_2 äquivalent zur Konditionierung bzgl. e_1 und e_2 . Somit gilt:

$$P(H|e_1, e_2) = P(H|\mathcal{E}_1, \mathcal{E}_2) = m(H|\mathcal{E}_1, \mathcal{E}_2). \quad (5.5)$$

Wendet man nun Bayes' Theorem auf die rechte Seite von (5.3) an und substituiert das Resultat in (5.5) für $m(H|\mathcal{E}_1, \mathcal{E}_2)$, so erhält man:

$$P(H|e_1, e_2) = \frac{P(e_1|H) P(e_2|H) P(H)^2}{P(e_1|H) P(e_2|H) P(H)^2 + P(e_1|\bar{H}) P(e_2|\bar{H}) P(\bar{H})^2}. \quad (5.6)$$

Die direkte Berechnung der a posteriori-Wahrscheinlichkeit mit Bayes' Theorem unter der bedingten Unabhängigkeitsannahme $P(e_1, e_2|H) = P(e_1|H)P(e_2|H)$ ergibt jedoch

$$P(H|e_1, e_2) = \frac{P(e_1|H) P(e_2|H) P(H)}{P(e_1|H) P(e_2|H) P(H) + P(e_1|\bar{H}) P(e_2|\bar{H}) P(\bar{H})}. \quad (5.7)$$

Offensichtlich werden die Vorabwahrscheinlichkeiten der Hypothesen in (5.6) gegenüber (5.7) überbewertet. Dieser Effekt verstärkt sich noch, je mehr Evidenzen miteinander kombiniert werden.

Um Dempsters Regel anwenden zu können, ist es daher notwendig, die Basiswahrscheinlichkeiten in sogenannte "Basissicherheitswerte" zu transformieren, die um den "überzähligen" Anteil der Vorabwahrscheinlichkeit reduziert sind.

Definition 5.1.5 (Basissicherheit)

Sei $m(H|\mathcal{E})$ wie in Definition 5.1.4. Dann heißt

$$C(H|\mathcal{E}) = \frac{\frac{m(H|\mathcal{E})}{P(H)}}{\sum_{H \subseteq \Omega} \frac{m(H|\mathcal{E})}{P(H)}} \quad (5.8)$$

der *Basissicherheitswert* (*basic certainty value*) von H . Die Funktion

$$C(\cdot|\mathcal{E}) : 2^\Omega \rightarrow [0, 1]$$

wird als *Basissicherheit* (*basic certainty assignment*, *bca*) bezeichnet.

Im Gegensatz zu einer Basiswahrscheinlichkeit, die ein *absolute* Vertrauensmaß darstellt, ist eine Basissicherheit ein Maß für die *Veränderung* dieses Vertrauens aufgrund neuer Information. Unter diesem Gesichtspunkt können Basissicherheiten mit den Größen *MB* und *MD* ("Measure of Belief" und "Measure of Disbelief") aus dem Certainty-Factor Ansatz verglichen werden (siehe [Shortliffe und Buchanan, 1975]).

Satz 5.1.1 [Yen, 1986] *Seien Θ_1 und Θ_2 zwei Evidenzenräume für einen gemeinsamen Hypothesenraum Ω . Ferner seien $e_1 \in \Theta_1$ und $e_2 \in \Theta_2$. Für $H_1, H_2 \subseteq \Omega$ gelte $H_1 \in G(e_1)$, $H_2 \in G(e_2)$. \mathcal{E}_1 und \mathcal{E}_2 bezeichnen das Hintergrundwissen einer Beobachtung in Θ_1 und Θ_2 . Unter den beiden Annahmen*

$$P(e_1|H_1)P(e_2|H_2) = P(e_1, e_2|H_1 \cap H_2) \quad (5.9)$$

für $H_1 \cap H_2 \neq \emptyset$ und

$$P(\mathcal{E}_1|e_1)P(\mathcal{E}_2|e_2) = P(\mathcal{E}_1, \mathcal{E}_2|e_1, e_2) \quad (5.10)$$

gilt


$$\frac{\sum_{H_1 \cap H_2 = H} C(H_1|\mathcal{E}_1)C(H_2|\mathcal{E}_2)}{\sum_{H_1 \cap H_2 \neq \emptyset} C(H_1|\mathcal{E}_1)C(H_2|\mathcal{E}_2)} = C(H|\mathcal{E}_1, \mathcal{E}_2). \quad (5.11)$$

Gleichung (5.11) entspricht genau der Anwendung von Dempsters Kombinationsregel, deren spezifische Unabhängigkeitsannahme durch (5.10) ausgedrückt ist. Zusätzlich wird in (5.9) eine bedingte Unabhängigkeit zwischen den Evidenzen gefordert. Beide Annahmen sollen unten noch kurz diskutiert werden.

Das Ergebnis von (5.11) ist wiederum eine Basissicherheit. Um die aktualisierte Basiswahrscheinlichkeit zu erhalten, muß das Ausfaktorieren der Vorabwahrscheinlichkeit wieder ausgeglichen werden, und man erhält

$$m'(H|\mathcal{E}) = \frac{C(H|\mathcal{E})P(H)}{\sum_{H \subseteq \Omega} C(H|\mathcal{E})P(H)}. \quad (5.12)$$

Das Vorgehen bei der Kombination von Evidenzen kann somit folgendermaßen beschrieben werden:



Anmerkungen zu den Unabhängigkeitsannahmen:

1. Hinreichende Bedingungen für die erste Annahme (5.9) sind

$$P(e_i|H_i) = P(e_i|H_1 \cap H_2), \quad i = 1, 2 \quad (5.13)$$

und

$$P(e_1|H_1 \cap H_2)P(e_2|H_1 \cap H_2) = P(e_1, e_2|H_1 \cap H_2). \quad (5.14)$$

Dabei besagt (5.13), daß das Wissen einer Teilmenge von H_i die Wahrscheinlichkeit von e_i nicht beeinflusst, wenn bereits H_i mit Sicherheit bekannt war. (5.14) bedeutet, daß Elemente e_1, e_2 aus verschiedenen Evidenzquellen voneinander bedingt unabhängig sind, gegeben den nicht-leeren Durchschnitt von mit ihnen assoziierten Hypothesenmengen.

2. Die zweite Annahme entspricht Dempsters Voraussetzung für die Anwendbarkeit der Kombinationsregel

$$P(e_1|\mathcal{E}_1)P(e_2|\mathcal{E}_2) = P(e_1, e_2|\mathcal{E}_1, \mathcal{E}_2),$$

die besagt, daß die einzelnen Evidenzen e_i bedingt unabhängig sind vom Hintergrundwissen \mathcal{E}_j der Beobachtung auf dem jeweils anderen Evidenzenraum.

5.2 Die Modifikation durch Guan und Bell

Der im vorigen Abschnitt beschriebene Ansatz Yens verbindet Elemente aus der Bayesschen Wahrscheinlichkeitstheorie und der Dempster-Shafer Theorie. Aufgrund der sich daraus ergebenden Einschränkungen hinsichtlich der darstellbaren Beziehungen zwischen Evidenzen und Hypothesen wird daher nicht deren gesamtes Potential bei der Repräsentation von Unwissenheit genutzt. Offensichtliche Kritikpunkte sind

1. die Beschränkung auf *elementare Evidenzen* sowie
2. die Forderung der *Disjunktheit der mit einer Evidenz assoziierten Hypothesen*.

Die Tatsache, daß i.a. keine sequentiellen Regelverknüpfungen möglich sind, da die Wahrscheinlichkeit auf dem Hypothesenraum nur unvollständig bekannt ist, soll erst bei der zusammenfassenden Analyse beider Ansätze in Abschnitt 5.4 betrachtet werden.

Um die oben genannten Defizite aus Yens System zu beheben, wird in [Guan und Bell, 1991] eine Modifikation vorgeschlagen, die vollständig auf der Dempster-Shafer Theorie aufbaut. Als Seiteneffekt entfällt dabei auch das Problem der Überbewertung von Vorabwahrscheinlichkeiten, das die Transformation von Basiswahrscheinlichkeiten in Basissicherheiten erforderlich machte. Die vorgenommenen Operationen, die nicht zur "klassischen" Dempster-Shafer Theorie gehören, werden jedoch nicht formal gerechtfertigt. Somit wird die in Abschnitt 1.2 aufgestellte Forderung der eindeutigen Interpretierbarkeit und Erklärbarkeit der getroffenen Entscheidungen verletzt, die dort zwar für Planerkennungssysteme formuliert wird, jedoch gleichermaßen auf Expertensysteme übertragbar ist. Eine formale Eingliederung in den Rahmen der Dempster-Shafer Theorie sowie eine probabilistische Semantik auf der Basis der in Kapitel 4 entwickelten Konzepte wird in Abschnitt 5.3 beschrieben werden. Zunächst werden jedoch die Grundlagen dieses Systems vorgestellt.

Die Beschränkung auf elementare Evidenzen (einelementige Teilmengen des Evidenzenraumes) wird durch eine Verallgemeinerung der probabilistischen Beobachtungsfunktion Γ^* aus Definition 5.1.1 zu einer Funktion mit Definitionsbereich $2^\Theta - \emptyset$ aufgehoben:

Definition 5.2.1 (DS-Beobachtungsfunktion)

Seien Θ und Ω wie oben. Dann ist die Funktion

$$\begin{aligned} \Delta : 2^\Theta - \emptyset &\rightarrow 2^{2^\Omega \times [0,1]} \\ E &\mapsto \{ \langle H_{E,1}, s_E(H_{E,1}|E) \rangle, \dots, \langle H_{E,n_E}, s_E(H_{E,n_E}|E) \rangle \} \end{aligned}$$

- mit
1. $H_{E,i} \neq \emptyset$ für $1 \leq i \leq n_E$
 2. $s_E(H_{E,i}|E) > 0$ für $1 \leq i \leq n_E$
 3. $\sum_{i=1}^{n_E} s_E(H_{E,i}|E) = 1$

eine *DS-Beobachtungsfunktion*.

Analog dazu kann die Information bzgl. gewichteter Verbindungen zwischen Evidenzen und Hypothesen auch als “Expertenregel” dargestellt werden:

Definition 5.2.2 (Regel)

Eine *Regel* oder *Expertenregel* ist ein Tripel

$$R = \langle \Theta, \Omega, \Delta \rangle,$$

wobei Θ und Ω den Evidenzen- und Hypothesenraum bezeichnen und Δ eine DS-Beobachtungsfunktion gemäß Definition 5.2.1 ist.


Eine andere Schreibweise ist

$$\begin{array}{llll} \mathbf{if} & E_1 & \mathbf{then} & H_{E_1,1} & \mathbf{with} & s_{E_1}(H_{E_1,1}) \\ & & & H_{E_1,2} & \mathbf{with} & s_{E_1}(H_{E_1,2}) \\ & & & \vdots & & \\ & & & H_{E_1,n_{E_1}} & \mathbf{with} & s_{E_1}(H_{E_1,n_{E_1}}) \\ \mathbf{else\ if} & E_2 & \mathbf{then} & H_{E_2,1} & \mathbf{with} & s_{E_2}(H_{E_2,1}) \\ & & & \vdots & & \end{array}$$

für alle $\emptyset \neq E_i \subseteq \Theta$. Die einzelnen Bestandteile der Fallunterscheidung einer Regel, die sich auf jeweils eine bestimmte Evidenz, etwa E_i , beziehen, werden auch als die *Klauseln* der Regel bezeichnet.

Anmerkungen:

1. In den folgenden Abschnitten wird eine solche Regel oft grafisch repräsentiert als



usw. für alle $\emptyset \neq E_i \subseteq \Theta$.

2. Oft wird eine solche Regel auch durch Angabe der $|2^\Theta| - 1$ Regelstärken s_E für $\emptyset \neq E \subseteq \Theta$ identifiziert:

$$R = \{s_E : 2^\Omega \rightarrow [0, 1] \mid \emptyset \neq E \subseteq \Theta\}.$$

3. Die Menge der mit einer (disjunktiven) Evidenz $E \subseteq \Theta$ assoziierten Hypothesen wird analog zu Definition 5.1.2 mit $G_\Delta(E)$ bezeichnet.

4. Ergänzt man die Angabe der numerischen Gewichte $s_E(H_{E,i}|E)$ aus obiger Definition um die Angabe

$$s_E(X|E) = 0, \text{ falls } X \notin G_\Delta(E),$$

so erhält man analog zu Definition 5.1.3 die mit E durch Δ assoziierte Regelstärke. Diese ist eine Basiswahrscheinlichkeit $s_E(\cdot)$, die im folgenden mit $s_E(\cdot|E)$ identifiziert wird. D.h. es wird davon ausgegangen, daß allen nicht explizit aufgeführten Hypothesenmengen ein Wert von 0 zugewiesen wird.

Die zweite Einschränkung betrifft die geforderte Disjunktheit der mit einer Evidenz assoziierten Hypothesen. Im Kontext der Dempster-Shafer Theorie ist diese Einschränkung überflüssig. In welchem speziellen Sinn die Gewichte s_E bei Guan und Bell bedingten Wahrscheinlichkeiten entsprechen, wird in Abschnitt 5.3 beschrieben.

Definition 5.2.3 (Hypothesenstärke)

Seien $c : 2^\Theta \rightarrow [0, 1]$ eine Basiswahrscheinlichkeit auf dem Evidenzenraum und $R = \{s_E \mid E \subseteq \Theta\}$ eine Regel. Dann heißt die Funktion

$$\begin{aligned} r : 2^\Omega &\rightarrow [0, 1] \\ H &\mapsto \sum_{E \subseteq \Theta} s_E(H) c(E) \end{aligned}$$

die durch die Evidenz c und Regel R induzierte Hypothesenstärke.

Anmerkungen:

1. In obiger Definition ersetzt c die diskrete Wahrscheinlichkeitsverteilung $P(\cdot|\mathcal{E})$ aus Yens Ansatz und erlaubt damit sowohl eine Bewertung disjunktiver Evidenzen, als auch die Repräsentation unvollständigen Wissens bzgl. dieser Evidenz (durch die von c induzierten Vertrauensintervalle). Das Hintergrundwissen \mathcal{E} der Evidenz c muß in diesem Fall also nicht so spezifisch sein, daß eine eindeutige Identifizierung der elementaren Evidenzen möglich ist. Im Extremfall genügt sogar die "leere" Basiswahrscheinlichkeit mit $c(\Theta) = 1$.
2. Die Definition von r entspricht der Anwendung der Regel R , getriggert durch die Evidenz c . Die einzelnen Summanden $s_E(H)c(E)$ entsprechen dabei der Anwendung jeweils einer Klausel von R , in der die Regelstärke $s_E(H)$ mit dem Grad der Erfülltheit $c(E)$ ihrer Prämisse E verknüpft wird.

Lemma 5.2.1 Die Funktion r aus Definition 5.2.3 ist eine Basiswahrscheinlichkeit.

Beweis: $r(\emptyset) = 0$, denn $s_E(\emptyset) = 0$ für alle $\emptyset \neq E \subseteq \Theta$.

$$\sum_{H \subseteq \Omega} r(H) = \sum_{H \subseteq \Omega} \sum_{E \subseteq \Theta} s_E(H) c(E)$$

$$\begin{aligned}
&= \sum_{E \subseteq \Theta} \underbrace{\sum_{H \subseteq \Omega} s_E(H)}_{=1} c(E) \\
&= \sum_{E \subseteq \Theta} c(E) \\
&= 1, \quad \text{da } c \text{ eine Basiswahrscheinlichkeit ist.}
\end{aligned}$$

□

Existiert bereits eine Bewertung des Hypothesenraumes in Form einer Basiswahrscheinlichkeit m auf 2^Ω , die entweder das einer Vorabwahrscheinlichkeit entsprechende situationsunabhängige Wissen über das Auftreten der Hypothesen repräsentiert oder aber durch die Verarbeitung früherer Evidenzen entstanden ist, so muß diese mit der neuen Hypothesenstärke kombiniert werden, und man erhält:

Definition 5.2.4 (aktualisierte Hypothesenbewertung)

Sei m eine Basiswahrscheinlichkeit auf dem Hypothesenraum 2^Ω , r eine Hypothesenstärke gemäß Definition 5.2.3. Dann ist

$$m' = m \oplus r$$

die *aktualisierte Hypothesenbewertung*.

Diese Berechnungsvorschriften lassen sich leicht auf den Fall mehrerer *voneinander unabhängiger* Beobachter verallgemeinern. Seien dazu $\Theta_1, \dots, \Theta_k$ Evidenzenräume, die nicht notwendigerweise voneinander verschieden sind. Auf diesen seien die Regeln R_1, \dots, R_k definiert mit

$$R_i = \langle \Theta_i, \Omega, \Delta_i \rangle.$$

Ferner seien eine Hypothesenbewertung m auf 2^Ω sowie die Evidenzen s_1, \dots, s_k auf den jeweiligen Evidenzenräumen gegeben, die die Hypothesenstärken r_1, \dots, r_k induzieren.

Definition 5.2.5 (aktualisierte Hypothesenbewertung)

In dieser Situation heißt

$$m' = m \oplus r_1 \oplus \dots \oplus r_k$$

die (*verallgemeinerte*) *aktualisierte Hypothesenbewertung*.

Diese Definition entspricht der simultanen Anwendung aller Regeln, wobei deren Resultate r_i gleichermaßen gewichtet in das Gesamtergebnis eingehen. Eine Methode, die die unterschiedliche Zuverlässigkeit der einzelnen Evidenzen berücksichtigt, wird in Abschnitt 6.2.1.5.2 beschrieben.

Beispiel 5.2.1 [Guan und Bell, 1991] Gegeben seien zwei Evidenzräume $\Theta_1 = \{e_1, e'_1\}$ und $\Theta_2 = \{e_2, e'_2\}$, ein Hypothesenraum $\Omega = \{h, h'\}$ sowie folgende Regelstärken:

$$s_{e_1}(X) = \begin{cases} 0.8, & X = \{h\} \\ 0.0, & X = \{h'\} \\ 0.2, & X = \Omega \end{cases} \quad s_{e'_1}(X) = \begin{cases} 0.0, & X = \{h\} \\ 0.5, & X = \{h'\} \\ 0.5, & X = \Omega \end{cases} \quad s_{\Theta_1}(X) = \begin{cases} 0.4, & X = \{h\} \\ 0.25, & X = \{h'\} \\ 0.35, & X = \Omega \end{cases}$$

für Evidenzraum Θ_1 sowie

$$s_{e_2}(X) = \begin{cases} 1.0, & X = \{h\} \\ 0.0, & X = \{h'\} \\ 0.0, & X = \Omega \end{cases} \quad s_{e'_2}(X) = \begin{cases} 0.0, & X = \{h\} \\ 0.8, & X = \{h'\} \\ 0.2, & X = \Omega \end{cases} \quad s_{\Theta_2}(X) = \begin{cases} 0.5, & X = \{h\} \\ 0.4, & X = \{h'\} \\ 0.1, & X = \Omega \end{cases}$$

für Θ_2 . Dabei wurden bei der Indizierung wiederum die einelementigen Mengen mit ihrem einzigen Element identifiziert, so daß z.B. s_{e_2} für $s_{\{e_2\}}$ steht.

Evidenzen c_1 und c_2 mit den Werten

$$c_1(X) = \begin{cases} 0.2, & X = \{e_1\} \\ 0.5, & X = \{e'_1\} \\ 0.3, & X = \Theta_1 \end{cases} \quad c_2(X) = \begin{cases} 0.0, & X = \{e_2\} \\ 1.0, & X = \{e'_2\} \\ 0.0, & X = \Theta_2 \end{cases}$$

führen zu den Hypothesenstärken

$$r_1(X) = \begin{cases} 0.28, & X = \{h\} \\ 0.325, & X = \{h'\} \\ 0.395, & X = \Omega \end{cases} \quad r_2(X) = \begin{cases} 0.0, & X = \{h\} \\ 0.8, & X = \{h'\} \\ 0.2, & X = \Omega \end{cases}$$

Kombiniert man diese mit einer Hypothesenbewertung m mit

$$m(X) = \begin{cases} 0.7, & X = \{h\} \\ 0.0, & X = \{h'\} \\ 0.3, & X = \Omega \end{cases} ,$$

so ergibt sich die aktualisierte Hypothesenbewertung m' mit

$$m'(X) = \begin{cases} 0.34011, & X = \{h\} \\ 0.58748, & X = \{h'\} \\ 0.07241, & X = \Omega \end{cases}$$

Die induzierten Vertrauensintervalle betragen damit $[0.34011, 0.41252]$ für $\{h\}$ und $[0.58748, 0.65989]$ für $\{h'\}$.

Anmerkung: Sind zu jedem Zeitpunkt exakte Beobachtungen möglich, die zu einer Basiswahrscheinlichkeit c_i mit genau *einem* Fokalelement \hat{E}_i führen, so ist die induzierte Hypothesenstärke identisch mit der entsprechenden Regelstärke $s_{\hat{E}_i}$. Im obigen Beispiel ist dies für Θ_2 der Fall mit $\hat{E}_2 = \{e'_2\}$.

5.3 Eine wahrscheinlichkeitstheoretische Semantik für das System von Guan und Bell

Während der vorangehende Abschnitt die Grundlagen des Ansatzes von Guan und Bell auf der Basis von [Guan und Bell, 1991] beschrieben hat, wird nun eine über diese Arbeit hinausgehende semantische Charakterisierung auf der Basis der in Kapitel 4 eingeführten Konzepte erarbeitet. Das zentrale Ergebnis ist dabei die Interpretation der Berechnung der Hypothesenstärke als eine spezielle Instanz der Regel der totalen Wahrscheinlichkeit (siehe Satz 5.3.1). Die zur Integration in den Kontext des evidenzbasierten Schließens zu untersuchenden Punkte sind dabei

1. die Repräsentation einer Evidenz mittels einer Basiswahrscheinlichkeit c auf dem Hypothesenraum Θ nach Definition 5.2.3,
2. die einer DS-Beobachtungsfunktion entsprechenden Regeln, wobei vor allem eine exakte Charakterisierung der assoziierten numerischen Gewichte erforderlich ist,
3. die Berechnungsvorschrift für die Hypothesenstärke r gemäß Definition 5.2.3 und ihre Verknüpfung mit einer Vorabbewertung der Hypothesen aus Definition 5.2.4 sowie
4. eine Beschreibung des durch eine Evidenz ausgelösten Informationsflusses vom Evidenzen- zum Hypothesenraum.

Zunächst seien dazu die beiden Sprachen \mathcal{S}_{ev} und \mathcal{S}_{hyp} definiert, mit deren Hilfe Evidenzen- und Hypothesenraum logisch beschrieben werden.

Definition 5.3.1 (Evidenzen- und Hypothesensatzraum)

\mathcal{S}_{ev} ist der über dem Alphabet Θ nach den Regeln von Definition 4.1.1 gebildete *Evidenzensatzraum*, während \mathcal{S}_{hyp} der entsprechend über dem Alphabet Ω gebildete *Hypothesensatzraum* ist.

Somit bilden die einzelnen Elemente des Evidenzenraums Θ und des Hypothesenraums Ω die Atome der jeweiligen Sprachen. Die Mengenoperationen \cap , \cup und Komplementbildung finden ihre Entsprechungen in den logischen Konnektoren \wedge , \vee und \neg .

Definition 5.3.2 (Evidenzen- und Hypothesenraum)

Die den beiden Sprachen \mathcal{S}_{ev} und \mathcal{S}_{hyp} zugeordneten Ereignisräume

$$\Phi(\mathcal{S}_{ev}) = \text{Obj}(\mathcal{S}_{ev})/\Leftrightarrow \quad \text{und} \quad \Phi(\mathcal{S}_{hyp}) = \text{Obj}(\mathcal{S}_{hyp})/\Leftrightarrow$$

werden als (*logischer*) *Evidenzenraum* und (*logischer*) *Hypothesenraum* bezeichnet.

Notationen:

Das logische Produkt der beiden Satzräume gemäß Definition 4.1.17 ist $\mathcal{S} = \mathcal{S}_{ev} \otimes \mathcal{S}_{hyp}$. Die marginalen epistemischen Mengen $\hat{\mathbf{e}}_{ev}(E)$ für $E \in \Phi(\mathcal{S}_{ev})$ ($\hat{\mathbf{e}}_{hyp}(H)$ für $H \in \Phi(\mathcal{S}_{hyp})$) sind gemäß Definition 4.1.21 die jeweiligen Mengen der möglichen Welten des Produktuniversums $\mathcal{U}_{\otimes}(\mathcal{S}_{ev} \otimes \mathcal{S}_{hyp})$, in denen E (H) der spezifischste objektive Satz aus $\Phi(\mathcal{S}_{ev})$ ($\Phi(\mathcal{S}_{hyp})$) ist, der dem Agenten bekannt ist.

Die marginalen epistemischen Algebren des Produktuniversums $\mathcal{U}_{\otimes}(\mathcal{S}_{ev} \otimes \mathcal{S}_{hyp})$, die die Mengen $\hat{\mathbf{e}}_{ev}(E)$ bzw. $\hat{\mathbf{e}}_{hyp}(H)$ umfassen, werden mit Ω_E^{ev} bzw. Ω_E^{hyp} bezeichnet, ihre Produktalgebra mit $\hat{\Omega}_E$ (siehe Definition 4.1.22). $\mathbf{e}(X) \in \hat{\Omega}_E$ ist eine epistemische Menge in der Produktalgebra (siehe Satz 4.1.7).

Lemma 5.3.1 *Für die epistemischen Mengen $\mathbf{e}(E)$ mit $E \in \Phi(\mathcal{S}_{ev})$ gilt nach dem Kombinationssatz 4.1.7 insbesondere*

$$\begin{aligned} \mathbf{e}(E) &= \bigcup_{\substack{E' \in \Phi(\mathcal{S}_{ev}), H \in \Phi(\mathcal{S}_{hyp}) \\ E' \wedge H \Leftrightarrow E}} [\hat{\mathbf{e}}_{ev}(E') \cap \hat{\mathbf{e}}_{hyp}(H)] \\ &= \bigcup_{H \in \Phi(\mathcal{S}_{hyp})} [\hat{\mathbf{e}}_{ev}(E) \cap \hat{\mathbf{e}}_{hyp}(H)] \\ &= \hat{\mathbf{e}}_{ev}(E) \cap \bigcup_{H \in \Phi(\mathcal{S}_{hyp})} \hat{\mathbf{e}}_{hyp}(H) \\ &= \hat{\mathbf{e}}_{ev}(E) \end{aligned}$$

und entsprechend für die Mengen $\mathbf{e}(H)$ mit $H \in \Phi(\mathcal{S}_{hyp})$.

Das bedeutet, daß die Wahrscheinlichkeiten der Mengen $\mathbf{e}(E)$ ($\mathbf{e}(H)$) in $\hat{\Omega}_E$ eindeutig durch Angabe der entsprechenden Werte in den Marginalalgebren Ω_E^{ev} (Ω_E^{hyp}) bestimmt sind und umgekehrt (dies ergibt sich unmittelbar aus der Definition der Produktalgebra).

5.3.1 Evidenz und Basiswahrscheinlichkeiten

Sei zunächst eine Evidenz c mit genau einem Fokalelement $E_0 = \{e_1, \dots, e_l\} \subseteq \Theta$ gegeben. Nach den Ausführungen von Kapitel 4 bedeutet dies, daß die aktuelle Beobachtung als stärkste Aussage gerade “die beobachtete Evidenz ist ein Element von E_0 ” zuläßt. Auf der logischen Seite kann dies durch die Formel $\mathbf{K}_{\mathbf{e}}E_0 \Leftrightarrow \mathbf{K}_{\mathbf{e}}(e_1 \vee \dots \vee e_l)$ dargestellt werden, d.h. die Schlußfolgerung aus einer Beobachtung ist die spezifischste Aussage, die zum Wissen des Beobachters gehört.

Die numerische Zuordnung $c(E_0) = 1$ und $c(E') = 0$ für alle $E' \neq E_0$ entspricht einer Wahrscheinlichkeitsverteilung P über der marginalen epistemischen Algebra Ω_E^{ev}

mit assoziierter Wahrscheinlichkeitsmasse m (siehe Definition 4.1.14) mit

$$m(X) = P(\hat{\mathbf{e}}_{ev}(X)) = P(\mathbf{e}(X)) = P(\mathbf{K}_e X) = \begin{cases} 1, & X = E_0 \\ 0, & \text{sonst} \end{cases}$$

Berücksichtigt man explizit das Hintergrundwissen \mathcal{E} dieser Beobachtung, so entspricht $m(X)$ der bedingten Wahrscheinlichkeit $P(\mathbf{e}(X)|\mathcal{E})$. Der Effekt von \mathcal{E} – nämlich die Identifizierung der spezifischsten Charakterisierung E_0 der aktuellen Beobachtung – führt dazu, daß alle Welten $\mathcal{W} \notin \mathbf{e}(E_0)$ inkompatibel mit dem Wissensstand des Beobachters werden.

Im allgemeinen Fall ist die Evidenz \mathcal{E} jedoch nicht spezifisch genug, eine einzige Teilmenge des Evidenzenraumes exakt zu identifizieren. In diesem Fall ergibt sich eine Basiswahrscheinlichkeit c mit den Fokalelementen $E_1, \dots, E_n \subseteq \Theta, n \geq 1$. Der Effekt von \mathcal{E} ist in diesem Fall eine Wahrscheinlichkeitsverteilung auf Ω_E^{ev} mit assoziierter Masse

$$m(X) = P(\hat{\mathbf{e}}_{ev}(X)) = P(\mathbf{e}(X)) = P(\mathbf{K}_e X) = c(X), \quad (5.15)$$

wobei $m(X) = 0$ für alle $x \neq E_1, \dots, E_n$. Alle Welten, die *nicht* zu einer der Mengen $\hat{\mathbf{e}}_{ev}(E_i), i = 1, \dots, n$ gehören, sind mit der aktuellen Beobachtung und dem daraus gewonnenen Wissen inkompatibel, da sie die Formel

$$\mathbf{K}_e E_1 \vee \dots \vee \mathbf{K}_e E_n$$

nicht erfüllen, die die Gesamtheit des aus \mathcal{E} gezogenen Wissens des Beobachters beschreibt. Da die einzelnen Disjunkte $\mathbf{K}_e E_i$ sich gegenseitig ausschließen, kann jede Welt nur zu *einer* der Mengen $\hat{\mathbf{e}}_{ev}(E_i)$ (bzw. $\mathbf{e}(E_i)$) gehören (vgl. die Anmerkungen zu Definition 4.1.13).

Die Repräsentation einer Evidenz mittels einer Basiswahrscheinlichkeit c entspricht somit im Modell des evidenzbasierten Schließens einer Klassifikation der mit dem aus der Evidenz gezogenen Wissen des Beobachters kompatiblen Welten bzgl. der spezifischsten darin möglichen Aussagen und einer quantitativen Bewertung dieser Klassen entsprechend ihrer jeweiligen Wahrscheinlichkeiten. Der auf der logischen Seite entscheidende Operator ist \mathbf{K} bzw. der aus ihm abgeleitete Operator \mathbf{K}_e , da eine Evidenz lediglich das *Wissen* des Beobachters über die Welt, nicht aber die Welt selbst beeinflusst.

5.3.2 Regeln und Konditionale

Die einer DS-Beobachtungsfunktion entsprechenden Regeln stellen jeweils gewichtete Verbindungen zwischen Evidenzen und Hypothesen her. Der qualitative Anteil einer solchen Regelklausel $E \longrightarrow H$ läßt sich als Konditional im gemeinsamen Sprachraum \mathcal{S} darstellen (genauer in der entsprechenden Erweiterung $\mathcal{S}^+ := (\mathcal{S}_{ev} \otimes \mathcal{S}_{hyp})^+$ gemäß Definition 4.2.3), wobei die Prämisse jeweils ein Element aus \mathcal{S}_{ev} und die Konklusion aus \mathcal{S}_{hyp} ist. Die syntaktische Form ist dabei so eingeschränkt, daß jedes der Klausel einer Regel entsprechende Konditional von der Form $(\mathbf{K}_e H | \mathbf{K}_e E)$ ist.

Dies ist wie folgt einzusehen: Als Resultat der Propagierung numerischer Gewichte vom Evidenzen- zum Hypothesenraum ergibt sich eine Basiswahrscheinlichkeit auf letzterem, die in der Theorie des evidenzbasierten Schließens einer Wahrscheinlichkeitsmasse $P(\mathbf{e}(\cdot))$ entspricht. \mathbf{K}_e ist das syntaktische Äquivalent zur Funktion \mathbf{e} innerhalb der zugrundeliegenden Modallogik. Die Evidenzen selbst werden ebenfalls mit einer Basiswahrscheinlichkeit bewertet, die eine entsprechend feine Einteilung des Evidenzenraumes in die $\mathbf{e}(E)$ erlaubt, dabei aber gleichzeitig $2^{|\Theta|} - 1$ Regeln erforderlich macht – genau eine für jede nichtleere Teilmenge E von Θ (bzw. für jedes $E \in \Phi(\mathcal{S}_{ev})$), die auf der logischen Seite durch $\mathbf{K}_e E$ repräsentiert ist.³ Die formale Bestätigung für diese eingeschränkte Syntax ergibt sich aus der Diskussion der Berechnung der Hypothesenstärke im nächsten Abschnitt.

Gemäß der Konstruktion der Regelklauseln als spezielle Konditionale entsprechen die assoziierten Regelgewichte bedingten Wahrscheinlichkeiten

$$s_E(H) = P(\mathbf{K}_e H | \mathbf{K}_e E) = P(\mathbf{e}(H) | \mathbf{e}(E)) = P(\hat{\mathbf{e}}_{hyp}(H) | \hat{\mathbf{e}}_{ev}(E))$$

über dem Ereignisraum $\Phi(\mathcal{S}^+) = \Phi((\mathcal{S}_{ev} \otimes \mathcal{S}_{hyp})^+)$ (bzw. dem Produktuniversum der möglichen Welten).

Definition 5.3.3 (gewichtete Regelbasis)

Eine Regel R sei durch ihre Regelstärken s_E gegeben, d.h.

$$R = \{s_E \mid \emptyset \neq E \subseteq \Theta\}.$$

Die mit R assoziierte *gewichtete Regelbasis* ist die Menge

$$\begin{aligned} RB(R) &= \bigcup_{\emptyset \neq E \subseteq \Theta} \{ \langle (\mathbf{K}_e H | \mathbf{K}_e E), s_E(H) \rangle \mid H \subseteq \Omega \} \\ &= \bigcup_{\emptyset \neq E \subseteq \Theta} \{ \langle (\mathbf{K}_e H | \mathbf{K}_e E), P(\mathbf{K}_e H | \mathbf{K}_e E) \rangle \mid H \subseteq \Omega \} \end{aligned}$$

Diese bedingten Wahrscheinlichkeiten können als Einschränkungen bzgl. der durch eine gegebene Evidenz \mathcal{E} identifizierten Welten betrachtet werden (vgl. Abschnitt 5.3.1). Eine Angabe $\langle (\mathbf{K}_e H | \mathbf{K}_e E), 0.3 \rangle$ in einer Regelbasis steht somit für die generische Information, daß in 30 % aller Fälle, in denen sich E als stärkste Schlußfolgerung der Evidenz ergibt, auf die Hypothese H geschlossen werden kann (wenn man etwa eine frequentistische Interpretation der Wahrscheinlichkeiten zugrundelegt und alle einzelnen Welten als gleich wahrscheinlich annimmt). Dies bedeutet, daß eine gewichtete Regelbasis $RB(R)$ situations- und damit evidenzunabhängige Information bzgl. der Gültigkeit verschiedener Hypothesen (bzw. der sie erfüllenden möglichen Welten) beinhaltet. Die darin enthaltenen bedingten Wahrscheinlichkeiten sind daher *nicht* als abgeleitete Größen zu betrachten.

³In Abschnitt 6.1.3.2.2 wird gezeigt werden, daß in vielen Fällen eine weitaus geringere Anzahl von Regeln ausreichend ist, um dieselbe Information zu repräsentieren.

5.3.3 Berechnung der Hypothesenstärke

Ziel dieses Abschnittes wird es sein aufzuzeigen, daß die Berechnungsvorschrift für die Hypothesenstärke r gemäß Definition 5.1.4 im wesentlichen eine spezielle Instanz der Regel der totalen Wahrscheinlichkeit darstellt. Das grundlegende Konzept dieser Regel besteht darin, einen gegebenen Ereignisraum in paarweise disjunkte Teile E_1, \dots, E_n aufzuspalten, die jeweilige bedingte Wahrscheinlichkeit eines Ereignisses H innerhalb eines Elementes E_i dieser Partition zu berechnen und mit der Wahrscheinlichkeit von E_i selbst zu multiplizieren. Die Summe aller dieser Produkte ergibt die Wahrscheinlichkeit von H . Angewandt auf das in Abschnitt 5.2 vorgestellte System, ist es somit zunächst erforderlich, eine Partition des gemeinsamen Satzraumes \mathcal{S}^+ mit den entsprechenden Marginalwahrscheinlichkeiten zu finden und gewisse Unabhängigkeitsannahmen zu rechtfertigen.




Abbildung 5.1: Bijektionen zwischen Evidenzenräumen und epistemischen Algebren.

Wie in Abschnitt 5.3.1 diskutiert, induziert eine Evidenz eine Wahrscheinlichkeitsmasse auf der marginalen epistemischen Algebra Ω_E^{ev} und erlaubt somit die Quantifizierung der Wahrscheinlichkeit $P(\mathbf{e}(E))$ in $\hat{\Omega}_E$ für jedes $E \subseteq \Theta$ – bzw. aus logischer Sicht von $P(\mathbf{K}_e E)$ für jedes $E \in \Phi(\mathcal{S}_{ev})$ (siehe Lemma 5.3.1). Die Mengen $\mathbf{e}(E)$ bilden eine Partition von $\mathcal{U}(\mathcal{S}^+)$ und entsprechen eineindeutig den marginalen epistemischen Mengen $\hat{\mathbf{e}}_{ev}$ (siehe Abbildung 5.1) im Produktuniversum (siehe Definition 4.1.21), die dieses somit ebenfalls partitionieren. Wie im vorigen Abschnitt erläutert wurde, induziert eine gegebene Evidenz eine Wahrscheinlichkeitsverteilung für die Elemente dieser Partition.

Anmerkung: Neben den in Abbildung 5.1 dargestellten Bijektionen existieren entsprechende Funktionen auch für den Hypothesenraum und die mit ihm zusammen-

hängenden epistemischen Algebren.

Da die Regeln selbst als spezielle Ereignisse in \mathcal{S}^+ repräsentiert sind, muß die Unabhängigkeit von Ereignissen $\mathbf{K}_e E$ mit $E \in \Phi(\mathcal{S}_{ev})$ und Regeln $(\mathbf{K}_e H | \mathbf{K}_e E)$ mit $H \in \Phi(\mathcal{S}_{hyp})$ sichergestellt werden in dem Sinne, daß

$$P(\text{appl}(\mathbf{K}_e H | \mathbf{K}_e E)) = P(\mathbf{K}_e E \wedge (\mathbf{K}_e H | \mathbf{K}_e E)) = P(\mathbf{K}_e E) \cdot P(\mathbf{K}_e H | \mathbf{K}_e E).$$

Seien dazu \mathcal{E}_1 die Hintergrundinformation der Beobachtung, die zur Quantifizierung von $P(\mathbf{K}_e E)$ geführt hat und \mathcal{E}_2 das Wissen zur Berechnung der Regelgewichte. Dann läßt sich obige Unabhängigkeitsannahme durch zwei bedingte Unabhängigkeiten formulieren:

$$P(\mathbf{K}_e E | \mathcal{E}_1, \mathcal{E}_2) = P(\mathbf{K}_e E | \mathcal{E}_1) \quad (5.16)$$

$$P((\mathbf{K}_e H | \mathbf{K}_e E) | \mathcal{E}_1, \mathcal{E}_2) = P(\mathbf{K}_e H | \mathbf{K}_e E, \mathcal{E}_1, \mathcal{E}_2) = P(\mathbf{K}_e H | \mathbf{K}_e E, \mathcal{E}_2). \quad (5.17)$$

Diese Annahmen sind gerechtfertigt durch die Tatsache, daß \mathcal{E}_1 eine aktuelle Beobachtung beschreibt, während \mathcal{E}_2 situationsunabhängiges, generisches Wissen verkörpert. Werden die Evidenzen \mathcal{E}_1 und \mathcal{E}_2 vernachlässigt, so können die rechte Seite von (5.16) mit der Marginalwahrscheinlichkeit $P(\mathbf{K}_e E)$ und das letzte Glied von (5.17) mit der bedingten Wahrscheinlichkeit $P(\mathbf{K}_e H | \mathbf{K}_e E)$ identifiziert werden.

Anmerkung: Da die bedingten Wahrscheinlichkeiten *keine* abgeleiteten Größen darstellen, ist der Wert für $P(\mathbf{K}_e H | \mathbf{K}_e E)$ auch für den Fall $P(\mathbf{K}_e E) (= P(\mathbf{K}_e E | \mathcal{E}_1)) = 0$ definiert.

Mit diesen Vorbedingungen läßt sich nun das zentrale Ergebnis dieser Untersuchung herleiten, das die Grundlage für die Angabe einer wahrscheinlichkeitstheoretischen Semantik für das in Abschnitt 5.2 vorgestellte System von Guan und Bell bildet und somit diesen in der Originalarbeit [Guan und Bell, 1991] nicht berücksichtigten Aspekt abdeckt.

Satz 5.3.1 *Die Hypothesenstärke*

$$r(H) = \sum_{E \subseteq \Theta} s_E(H) c(E)$$

nach Definition 5.1.4 ist eine Wahrscheinlichkeitsfunktion auf der epistemischen Algebra $\hat{\Omega}_E$ und induziert daher eine eindeutig bestimmte Wahrscheinlichkeitsfunktion auf Ω_E^{hyp} .

Beweis:
$$r(H) = \sum_{E \subseteq \Theta} s_E(H) c(E) \quad (5.18)$$

$$= \sum_{E \in \Phi(\mathcal{S}_{ev})} P(\mathbf{K}_e H | \mathbf{K}_e E) P(\mathbf{K}_e E) \quad (5.19)$$

$$= \sum_{\mathbf{e}(E) \subseteq \mathcal{U}(\mathcal{S}^+)} P(\mathbf{e}(H) | \mathbf{e}(E)) P(\mathbf{e}(E)) \quad (5.20)$$




Abbildung 5.2: Der durch eine Evidenz ausgelöste Informationsfluß.

$$= \sum_{\hat{\mathbf{e}}_{ev}(E) \subseteq \mathcal{U}(\mathcal{S}^+)} P(\mathbf{e}(H) | \hat{\mathbf{e}}_{ev}(E)) P(\hat{\mathbf{e}}_{ev}(E)) \quad (5.21)$$

$$= P(\mathbf{e}(H)) \quad (5.22)$$

$$= P(\hat{\mathbf{e}}_{hyp}(H)) \quad (5.23)$$

(5.18)=(5.19): aufgrund der Bijektion $2^\Theta \xrightarrow{\sim} \Phi(\mathcal{S}_{ev})$, Definition 5.3.3 und Gleichung (5.15)

(5.19)=(5.20): gemäß Definition 4.1.16

(5.20)=(5.21): siehe Lemma 5.3.1

(5.21)=(5.22): Anwendung der Regel der totalen Wahrscheinlichkeit ($\mathcal{U}(\mathcal{S}^+)$ wird durch die $\hat{\mathbf{e}}_{ev}(E)$ partitioniert)

(5.22)=(5.23): siehe Lemma 5.3.1

Somit gilt für alle $H \in \Phi(\mathcal{S}_{hyp})$:

$$r(H) = P(\mathbf{K}_e H) = P(\mathbf{e}(H)) = P(\hat{\mathbf{e}}_{hyp}(H)). \quad (5.24)$$

□

Gemäß Gleichung (5.24) bestimmt r eindeutig die Wahrscheinlichkeit der marginalen epistemischen Mengen $\hat{\mathbf{e}}_{hyp}(H)$ aller Elemente H des Hypothesenraums in der Produktalgebra $\hat{\Omega}_E$. Mit Lemma 5.3.1 ergeben sich eindeutig die Wahrscheinlichkeiten der Mengen $\hat{\mathbf{e}}_{hyp}(H)$:

$$P(\mathbf{e}(H)) = P(\hat{\mathbf{e}}_{hyp}(H)) \quad (5.25)$$

für alle $H \in \Phi(\mathcal{S}_{hyp})$.

Somit löst eine Evidenz c auf dem Evidenzenraum einen Informationsfluß in drei Schritten aus:

1. c definiert eine Wahrscheinlichkeitsmasse und somit eine eindeutige Wahrscheinlichkeitsverteilung auf der marginalen epistemischen Algebra Ω_E^{ev} . Gemäß Lemma 5.3.1 induziert diese eine Wahrscheinlichkeit auf der Produktalgebra $\hat{\Omega}_E$.
2. Da die $\mathbf{e}(E)$ eine Partition des Produktuniversums $\mathcal{U}(\mathcal{S}^+)$ bilden, kann unter Ausnutzung der in einer gegebenen gewichteten Regelbasis vorhandenen Information in Form bedingter Wahrscheinlichkeiten die Wahrscheinlichkeit *jedes* Ereignisses in $\hat{\Omega}_E$ berechnet werden.
3. Diese bestimmt eindeutig die Wahrscheinlichkeit von $\hat{\mathbf{e}}_{hyp}(H)$ in der marginalen epistemischen Algebra Ω_E^{hyp} .

Dieser Informationsfluß ist in Abbildung 5.2 nochmals dargestellt.

Die Berechnung der aktualisierten Hypothesenbewertung mittels Dempsters Regel gemäß Definition 5.2.4 setzt die Unabhängigkeit der aktuellen Evidenz c von den bisherigen Beobachtungen voraus, die die Berechnung der Vorabbewertung m des Hypothesenraumes ermöglichte. Diese Annahme ist gerechtfertigt, wenn Evidenzen schrittweise gesammelt werden und das Ergebnis der einzelnen Beobachtungen nicht durch vorherige Ergebnisse beeinflusst wird. Die formale Rechtfertigung des Kombinationsmechanismus \oplus selbst war bereits Gegenstand von Abschnitt 4.1.4.

5.4 Analyse der vorgestellten Systeme

Die wesentliche Leistung von Yens Ansatz besteht darin, daß die formale Grundlage für regelbasierte Systeme mit numerischen Regelgewichten auf der Basis von Wahrscheinlichkeitstheorie und Dempster-Shafer Theorie geschaffen wird. Im Gegensatz zu Systemen wie MYCIN mit dem Certainty-Factor Modell (siehe [Shortliffe und Buchanan, 1975]) werden hier sämtliche Definitionen und Berechnungsschritte formal gerechtfertigt und die Übereinstimmung mit dem Bayesschen Theorem gezeigt. Allerdings nutzt dieser Ansatz nicht die komplette Ausdruckstärke der Dempster-Shafer Theorie. Vielmehr bleibt ihr Einsatz auf die kompakte Repräsentation unvollständigen Wissens bzgl. bedingter Wahrscheinlichkeiten beschränkt, wie auch folgendes Zitat verdeutlicht:

“In fact, our model can be viewed as a Bayesian approach that uses the concept of mass distribution in the D-S framework to deal with incomplete information about conditional probabilities.” [Yen, 1989, S. 576]

Diese Einschränkung führt zu den genannten Problemen bei der Anwendung von Dempsters Regel, die den “Umweg” über die Basissicherheiten erforderlich macht und zusätzlich zu Restriktionen bzgl. der Gestalt von Expertenregeln führt. Diese erlauben nämlich lediglich *elementare Evidenzen*, also einelementige Teilmengen des Evidenzenraumes, als Prämissen und erfordern zusätzlich die Disjunktheit aller mit einer Evidenz assoziierten Hypothesen.

Diese beiden letzten Punkte waren u.a. die Motivation für die Verallgemeinerung von Yens Ansatz durch Guan und Bell. Dabei handelt es sich um ein vollständig auf Dempster-Shafer Theorie aufbauendes System, das diese Einschränkungen nicht benötigt. Im Gegensatz zu Yens Arbeit wird für diesen Ansatz jedoch keine formale Fundierung im Sinne einer Einbettung in die Dempster-Shafer Theorie oder Wahrscheinlichkeitstheorie gegeben. Dieses Defizit konnte durch Angabe einer auf der Basis der von Ruspini eingeführten Theorie des evidenzbasierten Schließens beruhende modallogische Charakterisierung in Abschnitt 5.3 beseitigt werden. Das zentrale Ergebnis war dabei die Herleitung der Berechnung der Hypothesenstärke nach Definition 5.1.4 als eine spezielle Instanz der Regel der totalen Wahrscheinlichkeit.

Eine weitere Einschränkung bei Yens Arbeit ist die Tatsache, daß Inferenzketten über mehrere Schritte, die eine sequentielle Regelkombination erforderlich machen, nicht möglich sind, da die vorhandene Information i.a. nicht ausreicht, um eine Wahrscheinlichkeitsverteilung auf einem bestimmten Raum *eindeutig* zu bestimmen. Dies wäre jedoch notwendig, da eine Regel bei Yen immer nur durch eine elementare Prämisse gefeuert werden kann. Dieser Aspekt der Regelverkettung wird bei Guan und Bell überhaupt nicht angesprochen. Die Herleitung einer entsprechenden Kombinationsformel wird Gegenstand von Abschnitt 6.2.1.6 sein.

Ist aufgrund der Beschränkung auf elementare Regelprämissen bei Yen jeweils eine diskrete Wahrscheinlichkeitsverteilung notwendig – also vollständiges probabilistisches Wissen –, wodurch bei einer Größe des Evidenzenraumes von $|\Theta| = n$ ebenfalls n Regeln zur vollständigen Abdeckung aller Möglichkeiten notwendig sind, so ist bei Guan und Bell nur unvollständiges Wissen in Form einer Basiswahrscheinlichkeit erforderlich. Dies hat jedoch zur Folge, daß zur vollständigen Erfassung aller möglichen Evidenzen 2^n Regeln angegeben werden müssen. Eine Möglichkeit zur Reduzierung dieser Anzahl wird in Abschnitt 6.1.3.2.2 beschrieben.

Ein weiteres Problem des verallgemeinerten Ansatzes liegt in der Formulierung der Regeln, die zu kontraintuitiven Ergebnissen führen kann. Dies ist speziell dann der Fall, wenn die Regelmenge unvollständig ist, d.h. weniger als 2^n verschiedene Regeln angegeben sind. Sei beispielsweise die Regel

$$\begin{aligned} \mathbf{if} \{e_1, e_2\} \mathbf{then} H_1 \mathbf{with} 0.3 \\ H_2 \mathbf{with} 0.7 \end{aligned}$$

gegeben. Die aktuelle Evidenz sei spezifisch genug, um ein einzelnes Element des Evidenzenraumes zu identifizieren, etwa

$$c(X) = \begin{cases} 1, & X = \{e_1\} \\ 0, & \text{sonst} \end{cases}$$

In dieser Situation ist obige Regel *nicht* anwendbar, obwohl die Prämisse schwächer als das tatsächliche Wissen bzgl. der Evidenz ist.

Der Grund dafür ist die Tatsache, daß aus logischer Sicht die Prämisse nicht $\mathbf{K}(e_1 \vee e_2)$ ist, sondern $\mathbf{K}_e(e_1 \vee e_2)$. Es wird also vorausgesetzt, daß *genau* $e_1 \vee e_2$ bekannt ist,

während die Evidenz $\mathbf{K}_e e_1$ validiert. Da keine Beziehung $\mathbf{K}_e e_1 \Rightarrow \mathbf{K}_e (e_1 \vee e_2)$ besteht, gibt es keine Möglichkeit, aus dem vorhandenen Wissen die für die Regelanwendung erforderliche Information abzuleiten.

Bezogen auf die numerische Berechnung gemäß Definition 5.2.3 bedeutet dies, daß $c(\{e_1, e_2\}) = 0$ ist und somit die entsprechende Regel keinen Beitrag zur resultierenden Hypothesenstärke liefert. Eine Methode zur Formulierung und Anwendung von Regeln, die dieses Problem umgeht, wird in Abschnitt 6.1.3.2.2 behandelt.

	Yen	Guan/Bell	DST
Evidenzen			
unsicher	✓	✓	✓
elementar	✓	✓	✓
disjunktiv	—	✓	✓
Hypothesen			
disjunkt	✓		
beliebig	—	✓	✓
Inferenzketten	—	—	✓
formale Basis	✓	— ¹	✓
Anzahl Regeln	n	2^n	$\leq 2^{n-2}$

Tabelle 5.1: Wichtige Eigenschaften der betrachteten Systeme.

Die Tabelle 5.1 faßt nochmals wichtige Aspekte dieser Diskussion zusammen. Die Abkürzung DST steht dabei für den neu entwickelten evidenztheoretischen Ansatz zur Planerkennung, der im folgenden Kapitel ausführlich beschrieben wird.

Erläuterungen zu Tabelle 5.1

—¹ Die Erweiterung der Dempster-Shafer Theorie um die zur Berechnung der Hypothesenstärke notwendige Operation (siehe Definition 5.2.3) wird nicht formal fundiert.

² Die Anzahl der im “DST”-Ansatz benötigten Regeln kann gegebenenfalls reduziert werden. Genaue Ausführungen dazu finden sich in Abschnitt 6.1.3.2.2.

Kapitel 6

Planerkennung mit der Dempster-Shafer Theorie

Dieses Kapitel stellt den Kern der vorliegenden Arbeit dar. Hier werden die wesentlichen Mechanismen zur Verknüpfung der Planerkennung mit der Dempster-Shafer Theorie vorgestellt. Der erste Abschnitt behandelt die verschiedenen Arten des einem Planerkenntner zur Verfügung stehenden Wissens und dabei insbesondere den Aspekt der Repräsentation dieser Informationen in der Dempster-Shafer Theorie. Der Prozeß der Planerkennung unter Berücksichtigung dieses Wissens in verschiedenen prototypischen Szenarien bildet den Schwerpunkt von Abschnitt 6.2, wobei u.a. verschiedene Sonderfälle des allgemeinen Ansatzes vorgestellt werden. Eine der zentralen Wissensquellen des vorgestellten Systems zur Planerkennung unter Unsicherheit ist das sogenannte *Benutzermodell*, das die Adaptierung des Planerkennungsprozesses an spezifische Eigenheiten einzelner Personen oder Personengruppen erlaubt. Wichtige Operationen im Zusammenhang mit einem solchen Benutzermodell werden in Abschnitt 6.3 vorgestellt, bevor Abschnitt 6.4 einige spezielle Aspekte der Planerkennung diskutiert und 6.5 die Komplexität der benötigten Berechnungen untersucht und insbesondere Methoden zur Effizienzsteigerung vorstellt. Alle wesentlichen Aspekte dieses Ansatzes sind in [Bauer, 1994a; Bauer, 1994b] und [Bauer, 1995a] enthalten.

Abschnitt 6.6 schließlich präsentiert eine Modifikation auf der Basis maschinellen Lernens, die eine Verfeinerung des Benutzermodells und somit eine präzisere Beschreibung des typischen Verhaltens eines Agenten ermöglicht. [Bauer, 1996a; Bauer, 1996c] decken den Kern dieser Erweiterung ab.

6.1 Wissensarten und Wissensrepräsentation

In diesem Abschnitt werden die beiden grundsätzlichen Wissensquellen eines Planerkenntners, ihre jeweilige Bedeutung für den Planerkennungsprozeß sowie ihre Repräsentation innerhalb der Dempster-Shafer Theorie vorgestellt. Im einzelnen handelt es sich dabei um eine Menge von *Plänen*, die den Handlungsspielraum eines zu beob-

achtenden Agenten innerhalb einer Domäne festlegt und somit die Hypothesen für dessen Verhalten zur Verfügung stellt sowie ein (quantitatives) *Benutzermodell*, das zur Fokussierung auf für einen Agenten typische Aktionssequenzen und Bewertung der einzelnen Hypothesen dient und somit die Funktionalität “konventioneller” Planerkenner erweitert.

Nach der Einführung eines Repräsentationsschemas für Pläne im folgenden Abschnitt wird in 6.1.2 der prinzipielle Inhalt eines quantitativen Benutzermodells diskutiert, dessen Ursprung und grundlegende Eigenschaften die Wahl der Dempster-Shafer Theorie als Repräsentationsformalismus zu motivieren helfen. Da dieses Benutzermodell einen zentralen Aspekt der vorliegenden Arbeit darstellt, ist den Operationen zur Initialisierung und Wartung der in ihm enthaltenen Daten nochmals Abschnitt 6.3.2 gewidmet.

6.1.1 Pläne und Planhierarchien

Die Menge \mathcal{P} von Plänen oder Planhypothesen, auf deren Basis der Planerkennungsprozeß arbeitet, weist oft die Struktur einer sogenannten *Planhierarchie* auf (siehe z.B. [Kautz und Allen, 1986; Bauer und Paul, 1993]) mit *Dekompositions-* und *Abstraktionsbeziehungen* zwischen ihren Elementen. In diesem Abschnitt wird zunächst ein allgemeines Repräsentationsschema vorgestellt, das von einer konkreten Repräsentationssprache abstrahiert und alle wesentlichen Aspekte einer Planhierarchie darstellen kann.

Definition 6.1.1 (Planhierarchie)

Eine *Planhierarchie* ist ein Tupel $\mathcal{H} = \langle \mathcal{P}, Dec, Ab \rangle$ mit

- einer *Planmenge* \mathcal{P} ,
- einer *Dekompositionshierarchie* Dec und
- einer *Abstraktionshierarchie* Ab .

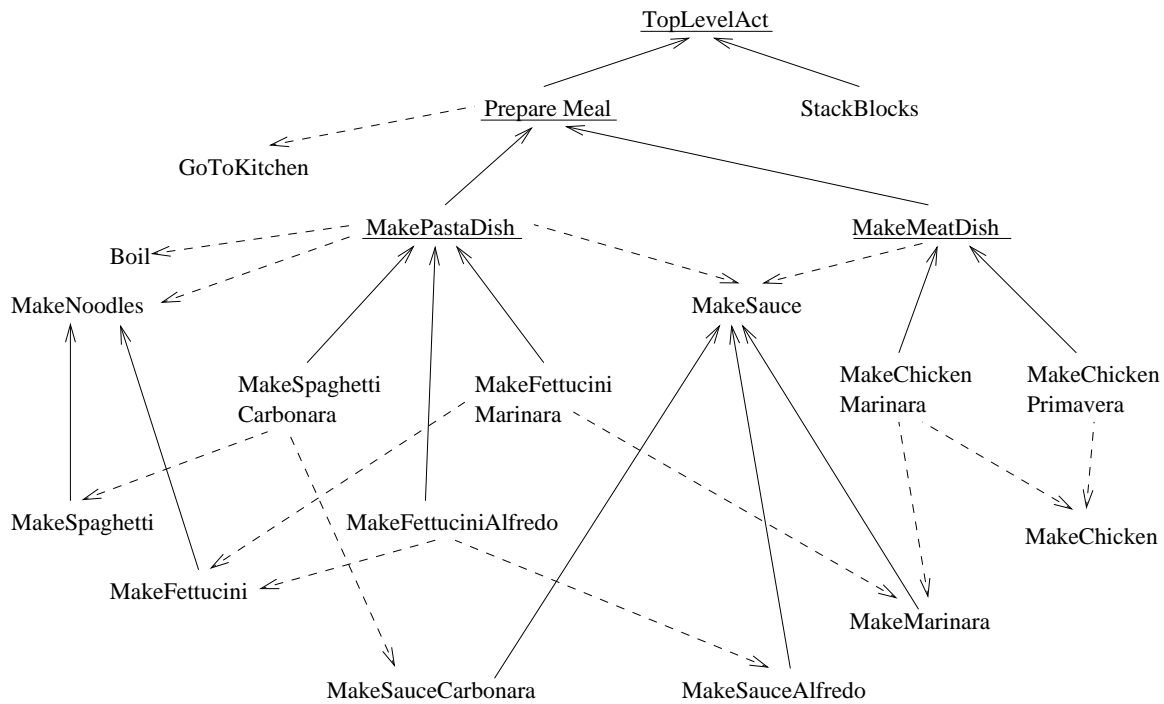
In obiger Definition besteht Dec aus einer Menge von *Plandekompositionen* $\langle p, A_p, C_p \rangle$, wobei $p \in \mathcal{P}$ der Name eines Planes ist (oder einfach ein *Plan*), A_p eine Menge von Aktionen – entweder primitiv oder abstrakt – und C_p eine Menge von Randbedingungen oder Constraints bzgl. der Elemente von A_p . Beispiele solcher Bedingungen sind Aussagen über die zeitliche Abfolge der einzelnen Aktionen innerhalb eines Planes oder Restriktionen bzgl. der durch diese Aktionen manipulierten Objekte, wie z.B. die Festlegung, daß zwei Aktionen aus A_p dasselbe Objekt als Parameter haben. A_p beinhaltet alle zur Ausführung von p notwendigen Aktionen, während C_p die vollständige Information darüber enthält, wie der Plan aus diesen Aktionen zusammengesetzt ist und somit ausgeführt werden kann.

Anmerkungen:

1. Diese Wahl der Repräsentation von Plänen unterstützt den Prozeß des Schließens von einer Evidenz (d.h. einer beobachteten Aktion) auf die verschiedenen Hypothesen (d.h. die potentiellen Pläne) in *einem* Schritt. Als Seiteneffekt ergibt sich die Tatsache, daß keine Dekompositionsbeziehungen zwischen Plänen erlaubt sind. Dies stellt jedoch keine Einschränkung hinsichtlich der Expressivität dieses Repräsentationsschemas dar: Sei P_1 ein Plan, der in die beiden Teilpläne P_a und P_b zerlegt werden kann. Diese wiederum sollen die Aktionen a_1, \dots, a_n bzw. b_1, \dots, b_l enthalten. Dann kann P_1 direkt durch Angabe der Aktionen $a_1, \dots, a_n, b_1, \dots, b_l$ (zusammen mit den entsprechenden Constraints) beschrieben werden. D.h. die Vererbung von Teilschritten von Teilplänen zum Gesamtplan wurde explizit gemacht. Diese *Lokalisierung von Information* ist sogar vorteilhaft, wenn etwa die nächste Aktion des Agenten vorhergesagt werden soll (siehe [Goodman und Litman, 1992]).
2. Die Angaben in C_p sind oftmals nicht so streng, daß es nur eine einzige Art der Durchführung von p mit den Aktionen aus A_p gibt. Ein Beispiel dafür sind *nichtlineare Pläne*, deren temporale Anordnung der Aktionen nur partiell ist und somit in konkreten Ausführungsinstanzen des Planes alle Reihenfolgen erlaubt, die mit dieser partiellen Ordnung konsistent sind.
3. In konkreten Anwendungen können die Constraints C_p entweder *explizit* gegeben sein, wie dies etwa in der Plansprache von [Kautz und Allen, 1986] der Fall ist, oder aber *implizit* in der Planbeschreibung enthalten sein wie in den Planformeln der Logik LLP, die in Abschnitt 7.2 vorgestellt wird.

Die *Abstraktionshierarchie* Ab läßt sich in zwei disjunkte Teile zerlegen: $Ab = Ab_p \dot{\cup} Ab_a$. Dabei ist Ab_p eine Menge von Paaren $\langle p_1, p_2 \rangle$ mit $p_1, p_2 \in \mathcal{P}$. Ein solches Paar steht für die Tatsache, daß Plan p_1 durch p_2 abstrahiert wird. Pläne, die niemals an der zweiten Stelle eines solchen Abstraktionspaares auftreten, werden als *Basispläne* bezeichnet, alle anderen als *abstrakte Pläne*. Letztere beschreiben *Klassen* von Basisplänen, die alle eine gemeinsame Eigenschaft aufweisen und daher alle vom selben Plan abstrahiert werden. Entsprechend beschreibt Ab_a die Abstraktionsbeziehungen zwischen Aktionen, die als *Basisaktionen* oder *abstrakte Aktionen* auftreten können. Auf der Basis dieser Konzepte können nun alle relevanten Aspekte von Planhierarchien uniform repräsentiert werden.

Beispiel 6.1.1 Abbildung 6.1 zeigt eine Planhierarchie, die im wesentlichen [Kautz und Allen, 1986] und [Allen *et al.*, 1991, Kapitel2] entnommen ist. Dabei stehen die durchgezogenen Pfeile für Abstraktionen, während die gestrichelten die Dekompositionsbeziehung zwischen Plänen und Aktionen darstellen. Die zugehörigen Constraints sind in dieser Abbildung nicht berücksichtigt. Die Namen abstrakter Pläne sind un-

Abbildung 6.1: Die Planhierarchie \mathcal{H} .

terstrichen. Die Menge der Pläne ist dabei

$$\mathcal{P} = \{ \text{MakeSpaghettiCarbonara, MakeFettuciniAlfredo,} \\ \text{MakeFettuciniMarinara, MakeChickenMarinara,} \\ \text{MakeChickenPrimavera, MakePastaDish,} \\ \text{MakeMeatDish, PrepareMeal,} \\ \text{StackBlocks, TopLevelAct} \}.$$

Die Abstraktionshierarchie umfasst die Paare

$$Ab_p = \{ \langle \text{MakeSpaghettiCarbonara, MakePastaDish} \rangle, \\ \langle \text{MakeFettuciniAlfredo, MakePastaDish} \rangle, \\ \langle \text{MakeFettuciniMarinara, MakePastaDish} \rangle, \\ \langle \text{MakePastaDish, PrepareMeal} \rangle, \\ \langle \text{PrepareMeal, TopLevelAct} \rangle, \\ \langle \text{MakeChickenMarinara, MakeMeatDish} \rangle, \\ \langle \text{MakeChickenPrimavera, MakeMeatDish} \rangle, \\ \langle \text{MakeMeatDish, PrepareMeal} \rangle, \\ \langle \text{StackBlocks, TopLevelAct} \rangle \}$$

$$Ab_a = \{ \langle \text{MakeSpaghetti, MakeNoodles} \rangle, \langle \text{MakeFettucini, MakeNoodles} \rangle, \\ \langle \text{MakeMarinara, MakeSauce} \rangle, \langle \text{MakeSauceAlfredo, MakeSauce} \rangle, \\ \langle \text{MakeSauceCarbonara, MakeSauce} \rangle, \\ \langle X, \text{Action} \rangle \text{ für } X \in \{ \text{MakeNoodles, MakeSauce, Boil,} \\ \text{MakeChicken, GoToKitchen} \} \}$$

Action steht dabei für die in \mathcal{H} nicht explizit aufgeführte Aktion, die alle anderen abstrahiert. Ein Beispiel einer Plandekomposition ist etwa

$$\langle \text{MakePastaDish,} \\ \{ \text{MakeNoodles, Boil, MakeSauce} \}, \\ \{ S(1, \text{plan}) = \text{MakeNoodles,} \\ S(2, \text{plan}) = \text{Boil,} \\ S(3, \text{plan}) = \text{MakeSauce,} \\ \text{object}(S(2, \text{plan})) = \text{result}(S(1, \text{plan})), \\ \text{holds}(\text{noodle}(\text{result}(S(1, \text{plan}))), \text{tn}), \\ \text{overlap}(T(S(1, \text{plan})), \text{tn}), \\ \text{during}(T(S(2, \text{plan})), \text{tn}) \} \rangle \quad (6.1)$$

Dabei ist tn ein Zeitintervall, die Terme $S(i, \text{plan})$ stehen für Teilschritte einer Planinstanz plan (die Zahlen repräsentieren *nicht* die Reihenfolge innerhalb des Planes). $S(1, \text{plan}) = \text{MakeNoodles}$ bedeutet beispielsweise, daß der Rollenfüller für diesen bestimmten Teilschritt des Gesamtplanes vom Typ MakeNoodles sein muß. Die Funktion T liefert das Zeitintervall, innerhalb dessen eine Aktion ausgeführt wird. *overlap* und *during* sind der Allenschen Zeitlogik entnommen (siehe [Allen, 1984; Allen und Hayes, 1985]), während *holds* die Gültigkeit einer Aussage während eines Zeitraumes bezeichnet, ähnlich zum Situationskalkül.

6.1.2 Agentenspezifisches Wissen

Dieser Abschnitt diskutiert die verschiedenen Aspekte der Information, die durch die Beobachtung eines Agenten bei der Durchführung bestimmter Aktionen gewonnen werden kann, ihre Rolle bei der Repräsentation seiner individuellen Präferenzen und ihre spezifischen Eigenschaften. Die daraus resultierenden Anforderungen werden die Wahl eines geeigneten Repräsentationsformalismus motivieren helfen.

Grundsätzlich können zumindest zwei verschiedene Arten von Daten aus solchen Beobachtungen abgeleitet werden, die im Zusammenhang mit Planerkennung eine Rolle spielen. Die erste betrifft das Auftreten typischer Aktionssequenzen oder Pläne im Handeln des Agenten. Angenommen, ein Agent bereitet sehr oft Nudelgerichte zu (um das Beispielszenario aus dem vorigen Abschnitt aufzugreifen). Folglich wird man ihn oft bei der Ausführung von Plänen im MakePasta -Teil der Planhierarchie

aus Abbildung 6.1 beobachten können, so daß ein Beobachter davon ausgehen wird, daß dessen zukünftiges Verhalten dem bisherigen ähneln wird.

Dies bedeutet, daß eine solche Analyse des Verhaltens des Agenten – beispielsweise durch Verwendung der Ergebnisse eines Planerkennungssystems oder einfach durch Angabe einer Selbsteinschätzung des Agenten – die Bestimmung der relativen Häufigkeit der durchgeführten Pläne erlaubt. Im Beispiel könnte das Ergebnis einer solchen Analyse durch eine Menge von Angaben der Art

“In 80% aller Fälle bereitete der Agent ein Nudelgericht zu.”

beschrieben werden. Diese quantitative Bewertung der Aktionshistorie des Agenten kann bei der Aufstellung einer numerischen Abschätzung seines zukünftigen Verhaltens auf der Basis bisheriger Beobachtungen helfen. Eine solche Bewertung kann mit einer Vorabwahrscheinlichkeit über der Menge aller möglichen Pläne verglichen werden.

Die dabei zugrundegelegte Annahme der Stetigkeit im Verhalten des Agenten ist natürlich strittig. Seine persönlichen Neigungen können sich ebenso ändern wie prinzipielle Rahmenbedingungen, wodurch die Ausführung vollständig anderer Pläne notwendig würde. Da jedoch auch solche Veränderungen spekulativ sind, ist es sinnvoll, sich auf die durch Beobachtungen gewonnenen Informationen zu stützen. Allerdings muß die prinzipielle Möglichkeit solcher Veränderungen bei der Entwicklung einer Repräsentation für die Präferenzen des Agenten berücksichtigt werden.

Der zweite Aspekt agentenspezifischer Information betrifft das gemeinsame Auftreten bestimmter Aktionen und Pläne. Wird beispielsweise der bereits erwähnte Agent beim Zubereiten von Fettucini beobachtet, und ist aus früheren Beobachtungen bekannt, daß er die Variante mit Sauce Alfredo derjenigen mit Sauce Marinara vorzieht, so kann von der aktuellen Beobachtung mit größerer Sicherheit auf MakeFettuciniAlfredo geschlossen werden. Diese Annahme könnte im Laufe einer Langzeitbeobachtung bestätigt werden, so daß eine Quantifizierung der tatsächlich ausgeführten Pläne in Situationen, in denen eine bestimmte Aktion beobachtet wurde, möglich wird.

Eine solche Beobachtung elementarer Aktionen ist in den meisten Anwendungen die Voraussetzung, um deduktiv oder abduktiv auf den Plan eines Agenten schließen zu können, der diese Aktionen als Teilschritte enthält. Berechnet man etwa die relative Häufigkeit des Auftretens eines Planes p im Zusammenhang mit Beobachtungen der Aktion a , so erhält man ein Maß dafür, wie stark eine solche Aktion als Evidenz auf eine bestimmte Hypothese hinweist. Dies ergibt eine Reihe von Aussagen der Art

“In $n\%$ aller Fälle, in denen der Agent beim Ausführen der Aktion a beobachtet wurde, verfolgte er den Plan p .”

Diese Information erlaubt eine Quantifizierung dessen, wie stark die Beobachtung a auf die Hypothese p verweist. Das formale Konzept der entsprechenden bedingten Wahrscheinlichkeit $P(p|a)$ umfaßt die wesentlichen Aspekte solcher Aussagen.

Diese beiden Arten von Informationen selbst sowie die Art und Weise, wie sie gewonnen werden, induzieren eine Reihe von Restriktionen, die von einem geeigneten

Repräsentationsformalismus erfüllt werden müssen. Als eine Folge des statistischen Ursprungs der agentenbezogenen Daten können keine definitiv wahren Aussagen über dessen zukünftiges Verhalten gemacht werden. Diese sind vielmehr mit einem gewissen Grad an *Unsicherheit* behaftet, der anzeigt, wie stark sie als Hypothesen durch frühere Evidenz unterstützt werden.

Eine gegebene Anzahl von Beobachtungen kann nur in den seltensten Fällen das gesamte Verhaltensrepertoire eines Agenten abdecken. Der erwähnte Agent kann z.B. im Laufe der Beobachtungen noch nie Pläne oder Aktionen außerhalb der Küchendomäne ausgeführt haben. Nichtsdestotrotz darf die prinzipielle Möglichkeit von Plänen außerhalb dieses eingeschränkten Spektrums nicht außer acht gelassen werden (im Beispiel von Abbildung 6.1 sind solche Pläne stellvertretend durch StackBlocks repräsentiert). Solche partielle *Unwissenheit* zeigt sich noch an einer anderen Stelle. Bei der Feststellung der Häufigkeit des Auftretens bestimmter Pläne im Verhalten des Agenten ist es oftmals nicht möglich, aufgrund der aktuellen Beobachtungen einen einzelnen Plan als zutreffende Hypothese zu identifizieren. Vielmehr erlaubt es die aktuelle Evidenz oft nur, die Menge der prinzipiell möglichen Hypothesen einzugrenzen auf eine mehrelementige Menge von Plänen, die alle gleichermaßen kompatibel mit den beobachteten Aktionen sind. Ohne Wissen über die Bevorzugung von Nudelgerichten gegenüber Fleischgerichten wäre es beispielsweise nicht möglich, aufgrund der Beobachtung *MakeFettucini* die Menge der kompatiblen Pläne enger als { *MakeFettuciniMarinara*, *MakeFettuciniAlfredo* } einzugrenzen. *Unwissenheit* bezeichnet hier die Unmöglichkeit, zwischen den Elementen einer solchen Hypothesenmenge aufgrund der gegebenen Evidenz zu unterscheiden und sich für eine davon zu entscheiden.

Das Verhalten des Agenten ist im Laufe der Zeit Schwankungen unterworfen. Neben den bereits erwähnten Veränderungen seiner Interessen können sich – je nach Domäne – seine Aufgaben oder Ziele verändern, oder er lernt neue Aktionen, die ihm das Erreichen seiner bisherigen Ziele auf anderen, u.U. effizienteren Wegen erlauben. Dies muß sich in der Repräsentation der Präferenzen des Agenten widerspiegeln, so daß geeignete *Aktualisierungsmethoden* zur Verfügung gestellt werden müssen. Zusätzlich zu diesen Präferenzen, die das Langzeitverhalten des Agenten wiedergeben, müssen auch aktuelle Beobachtungen in die Betrachtungen und Berechnungen einbezogen werden (d.h. *Evidenz* im Gegensatz zu generellem *Wissen* [Dubois und Prade, 1992]). Daher muß der verwendete Formalismus Mechanismen zur *Kombination und Integration von Evidenzen* bereitstellen.

Neben diesen Anforderungen, die direkt durch die zu repräsentierende Information induziert werden, benötigt der gesamte Formalismus eine *formale Semantik*, auf deren Grundlage die Berechnungsergebnisse eindeutig interpretiert und gegebenenfalls getroffene Entscheidungen gerechtfertigt werden können. Diese Kriterienliste wurde bei der Wahl der Dempster-Shafer Theorie als Repräsentationsformalismus berücksichtigt. Die folgenden Abschnitte zeigen, inwiefern die verschiedenen Anforderungen konkret umgesetzt werden.

6.1.3 Einbettung in die Dempster-Shafer Theorie

Ziel dieser Arbeit ist es, einen Bewertungsmechanismus für Planhypothesen auf der Basis der Dempster-Shafer Theorie zu entwickeln, der wesentliche Prinzipien des in Abschnitt 5.2 vorgestellten Systems übernimmt. Dazu ist es notwendig, das in der Planhierarchie und dem quantitativen Benutzermodell enthaltene Wissen in einer für die numerische Bewertung adäquaten Weise zu repräsentieren. Im einzelnen sind dazu erforderlich

- ein *Hypothesenraum* der Form 2^Ω über einer Menge Ω elementarer Hypothesen,
- ein *Evidenzenraum* der Form 2^Θ über einer Menge Θ elementarer Evidenzen und
- eine *DS-Beobachtungsfunktion*, die beide miteinander verbindet.

6.1.3.1 Hypothesen- und Evidenzenraum

Intuitiv ist klar, daß in einer Planhierarchie $\mathcal{H} = \langle \mathcal{P}, Dec, Ab \rangle$ die Menge \mathcal{P} der Pläne die Sammlung der Hypothesen darstellt und die in der Dekomposition aufgeführten Aktionen die entsprechenden möglichen Evidenzen repräsentieren. Die exakte Beziehung zwischen den Bestandteilen von \mathcal{H} und den Konstituenten eines DST-Systems gemäß obiger Aufzählung ist folgende:

Die Menge Ω aller elementaren Hypothesen wird gebildet von der Menge $\mathcal{P}_0 \subseteq \mathcal{P}$ der Basispläne. Abstrakte Pläne werden als die Vereinigung aller von ihnen abstrahierten Pläne betrachtet. Somit können alle Elemente aus \mathcal{P} in den Hypothesenraum $2^\Omega = 2^{\mathcal{P}_0}$ eingebettet werden:

Definition 6.1.2 (Planmenge)

Die mit einem Plan $p \in \mathcal{P}$ assoziierte *Planmenge* ist gegeben durch

$$M : \mathcal{P} \rightarrow 2^{\mathcal{P}_0}$$

$$p \mapsto \begin{cases} \{p\}, & p \in \mathcal{P}_0 \text{ Basisplan} \\ \bigcup_{\substack{p' \in \mathcal{P} \\ \langle p', p \rangle \in Ab_p}} M(p'), & \text{sonst} \end{cases}$$

Analog ist das Vorgehen in Bezug auf den Evidenzenraum 2^Θ . Auch hier stehen abstrakte Aktionen für die Menge aller von ihr abstrahierten Basisaktionen, deren Gesamtheit mit Θ bezeichnet wird. Für eine Aktion a wird $M(a) \subseteq \Theta$ als *Aktionsmenge* bezeichnet.

Anmerkungen:

1. Im folgenden werden die Pläne p und Aktionen a mit ihren assoziierten Plan- bzw. Aktionsmengen $M(p)$ bzw. $M(a)$ identifiziert, wenn keine Verwechslungsgefahr besteht.
2. Für $p \in \mathcal{P}$ steht die Menge $M(p) \subseteq \mathcal{P}_0$ steht für eine Klasse von Plänen, die alle eine gemeinsame Eigenschaft aufweisen wie z.B. gemeinsame Aktionen oder Teilziele. Abstrakte Aktionen $M(a) \subseteq \Theta$ fassen üblicherweise Basisaktionen mit zumindest teilweise identischen Effekten zusammen.
3. Definition 6.1.2 sowie ihre Entsprechung für den Fall des Evidenzenraumes implizieren eine Form der “Closed-World-Assumption”. Die Aussage $M(p) = H$ besagt nämlich, daß es außer den explizit in Ab aufgeführten Plänen keine anderen gibt, die ebenfalls von p abstrahiert werden. Dies entspricht dem Abschluß der Abstraktionshierarchie durch Circumscription, wie dies in [Kautz und Allen, 1986] beschrieben wird.

Für die Planhierarchie aus Abbildung 6.1 ergeben sich u.a. die folgenden Zuordnungen

$$\mathcal{P}_0 = \{ \text{MakeSpaghettiCarbonara, MakeFettuciniAlfredo, MakeFettuciniMarinara, MakeChickenMarinara, MakeChickenPrimavera, StackBlocks } \}$$

$$M(\text{MakePastaDish}) = \{ \text{MakeSpaghettiCarbonara, MakeFettuciniAlfredo, MakeFettuciniMarinara } \}$$

$$M(\text{TopLevelAct}) = \mathcal{P}_0 (= \Omega)$$

für den Hypothesenraum und z.B.

$$\Theta = \{ \text{MakeSpaghetti, MakeFettucini, Boil, GoToKitchen, MakeMarinara } \}$$

$$M(\text{MakeNoodles}) = \{ \text{MakeSpaghetti, MakeFettucini } \}$$

für den Evidenzenraum.

Liegt bereits Information bzgl. des Benutzerverhaltens in Form einer Basiswahrscheinlichkeit über $2^{\mathcal{P}_0}$ vor, so kann diese als initiale Hypothesenbewertung verwendet werden. Dabei ist wichtig, daß die Plausibilität aller Planhypothesen positiv ist, um nicht von vornherein den Hypothesenraum faktisch einzuschränken. Insofern ist die “leere” Basiswahrscheinlichkeit \tilde{m} mit $\tilde{m}(\mathcal{P}_0) = 1$ eine geeignete Wahl.

Ist die Information über das typische Benutzerverhalten dagegen *nicht* als Basiswahrscheinlichkeit verfügbar, sondern lediglich als eine Menge von Constraints, die den einer bestimmten Hypothesenmenge zugeordneten initialen Vertrauensgrad nach oben und unten beschränken, so kann daraus eine Basiswahrscheinlichkeit errechnet

werden, deren assoziierte Belief- und Plausibilitätswerte gerade diesen Schranken entsprechen. Das genaue Vorgehen ist in Abschnitt 6.3.1 beschrieben.

Eine solche initiale Hypothesenbewertung verändert sich innerhalb *eines* Planerkennungszklus, sobald neue Evidenzen verfügbar sind, d.h. neue Aktionen beobachtet wurden, sowie *nach einer Reihe* solcher Zyklen im Zuge der Adaptierung des Benutzermodells an das Langzeitverhalten des Benutzers. Ersteres wird in Abschnitt 6.2 beschrieben, während der zweite Punkt Gegenstand von Abschnitt 6.3.2 ist.

6.1.3.2 Die Beobachtungsfunktion

Weiterhin wird eine DS-Beobachtungsfunktion Δ gemäß Definition 5.2.1 bzw. die ihr entsprechenden Beobachtungsregeln benötigt, die numerisch gewichtete Verbindungen zwischen Evidenzen und Hypothesenmengen herstellt. Der *qualitative* Anteil einer solchen Funktion, d.h. die Aussage über die Existenz oder Nichtexistenz einer solchen Verbindung, läßt sich direkt aus den Plandekompositionen ablesen: Eine Aktion a weist als Evidenz auf einen Plan p hin, wenn sie Bestandteil seiner Dekomposition ist, d.h. wenn $a \in A_p$. Die Constraints C_p dieser Dekomposition werden hier zunächst außer acht gelassen. Deren Behandlung wird Gegenstand von Abschnitt 6.1.3.3 sein.

Notation: Um Aktionen bzw. Pläne als Teilmengen des Evidenzen- bzw. Hypothesenraumes kenntlich zu machen, werden diese im folgenden mit A bzw. H (und entsprechenden Indizes) bezeichnet.

Bei der numerischen Gewichtung sind zwei Fälle zu unterscheiden:

1. Es liegt Information über die relative Häufigkeit des gemeinsamen Auftretens gewisser Aktionen und Hypothesen im Benutzermodell vor. Gemäß der Diskussion von Abschnitt 5.3.2 sind die entsprechenden numerischen Angaben von der Form

$$P(\mathbf{K}_e H | \mathbf{K}_e A) = s_A(H) \in]0, 1]$$

mit $H \subseteq \mathcal{P}_0$ und $A \subseteq \Theta$. Sei

$$BM_0 = \{s_{A_1}(H_{11}), \dots, s_{A_1}(H_{1n_1}), s_{A_2}(H_{21}), \dots\}$$

die Menge aller solcher Angaben. Für $A_i \subseteq \Theta$ sei $\{H_{i1}, \dots, H_{in_i}\}$ die Menge aller Pläne, in deren Dekomposition A_i vorkommt. Dann ergeben sich daraus folgende Beobachtungsregeln für $A_i \subseteq \Theta$:¹

¹Um die Notation zu vereinfachen, werden hier und bei der weiteren Betrachtung von Beobachtungsregeln oftmals anstelle der mit Plänen assoziierten Planmengen $M(H_i)$ die Pläne H_i selbst als Konklusion verwendet.

$$\begin{array}{l}
 A_i \begin{array}{l} \nearrow \\ \rightarrow \\ \searrow \end{array} \begin{array}{l} H_{i1} \langle s_{A_i}(H_{i1}) \rangle \\ \vdots \\ H_{in_i} \langle s_{A_i}(H_{in_i}) \rangle \\ \{H_{i1}, \dots, H_{in_i}\} \setminus \bigcup_{\substack{j=1 \\ j \neq 1, \dots, n_i}}^{n_i} H_{ij} \langle 1 - \sum_{j=1}^{n_i} s_{A_i}(H_{ij}) \rangle \end{array}
 \end{array} \quad (6.2)$$

Die letzte Klausel verbindet dabei Aktion A_i mit all denjenigen Plänen, in deren Dekomposition sie vorkommt, für die jedoch keine numerische Information der Form $s_{A_i}(\cdot)$ vorlag. Das zuzuordnende numerische Gewicht ist eindeutig bestimmt durch die 3. Forderung aus Definition 5.2.1, in der festgelegt wird, daß sich alle Gewichte $s_{A_i}(\cdot)$ zu 1 aufaddieren.

Anmerkung: Falls $H_{ij} \neq \mathcal{P}_0$ für alle $j = 1, \dots, n_i$, so schließt obige Regel alle Pläne, die nicht in den $s_{A_i}(\cdot)$ vorkommen oder A_i nicht in ihrer Dekomposition enthalten, als mögliche Hypothesen aus: Betrachtet man s_{A_i} als Basiswahrscheinlichkeit auf $2^{\mathcal{P}_0}$, so ist für diese Pläne die induzierte Plausibilität 0.

Eine solche Formulierung der Regel macht also nur dann Sinn, wenn entweder das Benutzermodell den Fall $H_{ij} = \mathcal{P}_0$ vorsieht oder wenn Aktionen tatsächlich nur in den Plänen auftreten können, für die sie ein notwendiger Teilschritt sind. In den meisten Fällen jedoch enthalten Pläne gewisse "Freiheitsgrade" in dem Sinne, daß die Dekomposition zwar alle zu ihrer erfolgreichen Ausführung *notwendigen* Aktionen beinhaltet, darüberhinaus aber auch weitere "eingestreut" werden können, die nicht direkt zum eigentlichen Ziel des Planes beitragen. Als Folge kann diese Aktion natürlich nicht als Evidenz zugunsten dieses Planes gewertet werden. Es ist lediglich die Aussage möglich, daß die aktuelle Beobachtung die Hypothese weder bestätigt noch verwirft.

Soll diesem Fall ebenfalls Rechnung getragen werden, so ist in obiger Regel die Hypothesenmenge der letzten Klausel durch \mathcal{P}_0 zu ersetzen. Das zugehörige numerische Gewicht bleibt bestehen.

- Der zweite Fall betrifft die Situation, in der keinerlei numerische Information der Form $s_{A_i}(\cdot)$ vorliegt. In diesem Fall werden die Regeln folgendermaßen initialisiert:

$$\begin{array}{l}
 A_i \begin{array}{l} \nearrow \\ \searrow \end{array} \begin{array}{l} \bigcup_{j=1}^{n_i} H_{ij} \langle c_0 \rangle \\ \mathcal{P}_0 \langle 1 - c_0 \rangle \end{array}
 \end{array} \quad (6.3)$$

Für die Konstante c_0 gilt dabei folgendes: ist $0 < c_0 < 1$, so entspricht die Regel dem o.a. zweiten Fall, in dem Aktionen auch während eines Planes ausgeführt werden können, zu dem sie *nicht* als notwendiger Bestandteil gehören. Kann A_i hingegen ausschließlich innerhalb der Pläne $H_{i_1}, \dots, H_{i_{l_i}}$ ausgeführt werden, so ist $c_0 = 1$ zu wählen.

Anmerkungen:

- (a) Diese initiale Konstruktion einer Beobachtungsregel dient zwei Zielen. Da keinerlei Information darüber vorliegt, wie stark ein Vorkommen von A_i auf einen der Pläne H_{ij} hindeutet, ist es sinnvoll, das gesamte numerische Gewicht der Menge *aller* dieser Pläne zuzuordnen und eine Entscheidung zugunsten eines dieser Pläne zu verschieben, bis weitere Information, etwa aus zusätzlichen Beobachtungen, verfügbar ist. Das zweite Ziel ist es, die Anzahl der Fokalelemente der entsprechenden Regelstärken zu minimieren, um so die Komplexität der numerischen Berechnungen, speziell der Anwendung von Dempsters Kombinationsregel, zu begrenzen.
- (b) Gemäß der obigen Konstruktion erhält man Beobachtungsregeln lediglich für diejenigen Aktionen (bzw. die mit ihnen assoziierten Teilmengen des Evidenzenraumes), die in den Plandekompositionen auftreten. Da die Gesamtheit aller Regeln jedoch eine *totale* Beobachtungsfunktion darstellen soll, kann für alle $A \subseteq \Theta$, die *nicht* in der Dekomposition eines Planes vorkommen, die Regel

$$A \longrightarrow \mathcal{P}_0 \langle 1.0 \rangle \quad (6.4)$$

ergänzt werden, da solche Aktionen als Evidenzen keinerlei Information über das Auftreten eines bestimmten Planes liefern.

6.1.3.2.1 Verfeinerung der Beobachtungsfunktion

Anhand eines Beispiels soll zunächst klargemacht werden, daß die im letzten Abschnitt eingeführte Beobachtungsfunktion nicht direkt zur Planerkennung eingesetzt werden kann, da ansonsten kontraintuitive Ergebnisse wie beim System von Guan und Bell auftreten (vgl. Abschnitt 5.4). Eine mögliche Lösung dieses Problems besteht in einer Verfeinerung dieser Funktion.

Sei dazu die Planhierarchie \mathcal{H}' aus Abbildung 6.2 gegeben. Die Dekomposition von `MakePastaDish` enthält die abstrakte Aktion `MakeNoodles`, die der Teilmenge $\{ \text{MakeSpaghetti}, \text{MakeFettucini} \}$ des Evidenzenraumes entspricht. Die zugehörige Beobachtungsregel enthält u.a.

$$\{ \text{MakeSpaghetti}, \text{MakeFettucini} \} \longrightarrow \text{MakePastaDish} \langle v \rangle.$$

Dies entspricht auf der logischen Seite einem Konditional

$$\mathbf{K}_e \text{MakePastaDish} \mid \mathbf{K}_e (\text{MakeSpaghetti} \vee \text{MakeFettucini}),$$

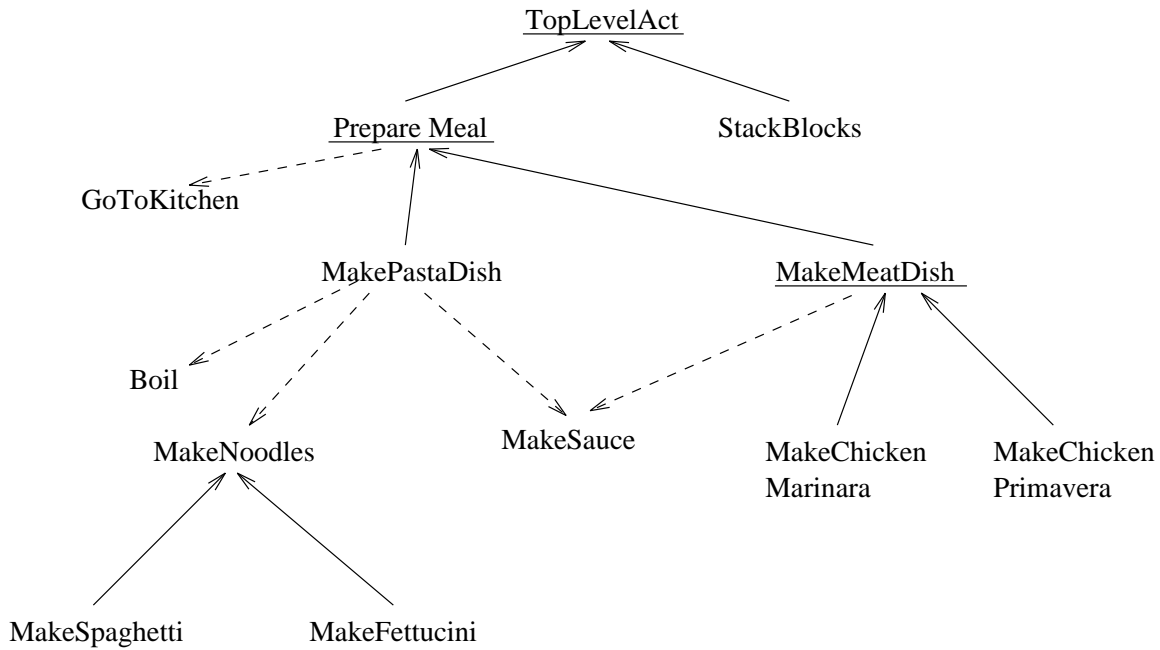


Abbildung 6.2: Eine modifizierte Planhierarchie.

das die Ableitung von MakePastaDish als stärkster Aussage erlaubt, sobald *genau* $\text{MakeSpaghetti} \vee \text{MakeFettucini}$ bekannt ist (siehe auch Abschnitt 5.3).

Wird nun die konkrete Aktion MakeSpaghetti beobachtet,² so ist es dennoch *nicht* möglich, daraus auf ein Auftreten von MakePastaDish zu schließen, da eine entsprechende Regel fehlt. Zum Feuern der o.a. Regel wäre die Wahrheit der Formel

$$\mathbf{K}_e(\text{MakeSpaghetti} \vee \text{MakeFettucini}) \Leftrightarrow \mathbf{K}(\text{MakeSpaghetti} \vee \text{MakeFettucini}) \wedge \bigwedge_{\beta \in \Phi(\mathcal{S})} \neg \mathbf{K}\beta$$

$$\begin{array}{l} \beta \Rightarrow (\text{MakeSpaghetti} \vee \text{MakeFettucini}) \\ \beta \not\Rightarrow (\text{MakeSpaghetti} \vee \text{MakeFettucini}) \end{array}$$

erforderlich gewesen. Gegeben ist jedoch $\mathbf{K}_e \text{MakeSpaghetti}$ mit

$$\mathbf{K}_e \text{MakeSpaghetti} \not\Rightarrow \mathbf{K}_e(\text{MakeSpaghetti} \vee \text{MakeFettucini}).$$

Es ist daher notwendig, für jede (qualitative) Klausel

$$A \longrightarrow H$$

mit $|A| > 1$, die aufgrund des Vorkommens von A in der Dekomposition von H erstellt wurde, ebenfalls alle Klauseln

$$A' \longrightarrow H$$

²Konkret sei etwa die Evidenz $c(\{\text{MakeSpaghetti}\}) = P(\mathbf{K}_e \text{MakeSpaghetti}) = 1$ gegeben.

für $\emptyset \neq A' \subseteq A$ hinzuzufügen und anschließend, wie im vorigen Abschnitt beschrieben, mit numerischen Gewichten zu versehen. Aus der logischen Sicht handelt es sich dabei um den Übergang von einem Konditional $\mathbf{K}_e H | \mathbf{K}_e A$ zu $\mathbf{K}_e H | \mathbf{K}_e A'$ mit $A' \Rightarrow A$.

Anmerkungen:

1. Aufgrund dieser speziellen syntaktischen Form der Beobachtungsregeln als Konditionale $\mathbf{K}_e H | \mathbf{K}_e A$ ist eine formale Beziehung zwischen der ursprünglichen und der abgeleiteten Regelklausel nicht direkt herstellbar. Der Grund dafür ist die Tatsache, daß zwei Formeln $\mathbf{K}_e A$ und $\mathbf{K}_e A'$ auch im Falle $A' \Rightarrow A$, $A' \not\Rightarrow A$ *nicht* in einem solchen Verhältnis zueinander stehen. Wären die Regeln als Konditionale mit Prämisse $\mathbf{K}A$ oder A formuliert, so ließe sich der Übergang von der Basisregel zur abgeleiteten Regel als iterierte Konditionierung beschreiben. Für $A' \Rightarrow A$ ist

$$(X | \mathbf{K}A') = (X | \mathbf{K}A) |_{A_0} = (X | \mathbf{K}A \wedge A_0),$$

wobei

$$A_0 \Leftrightarrow \bigwedge_{\substack{A'' : A' \Rightarrow A'' \\ A'' \Rightarrow A}} \neg \mathbf{K}_e A''.$$

Diese iterierte Konditionierung stellt einen Sonderfall der in [Schay, 1968] vorgeschlagenen konjunktiven Verknüpfung für Konditionale dar:

$$a|b \wedge c|d = a \wedge c|b \wedge d.$$

2. Werden die Beobachtungsregeln gemäß (6.3) initialisiert, so ergibt sich für eine Teilmenge $A' \subseteq \Theta$ des Evidenzenraumes u.a. die Regelklausel

$$A' \longrightarrow G_{\Delta}(A') \cup \bigcup_{A:A' \subset A} G_{\Delta}(A)$$

In diesem Fall ergeben sich bis zu $2^{|\Theta|} - 1$ Regeln mit jeweils zwei Klauseln.

3. Die “leere Beobachtungsregel” (6.4) wird *nicht* an die Teilmengen der jeweiligen Prämissen weitervererbt, da hier die assoziierte Hypothesenmenge leer ist: $G_{\Delta}(A) = \emptyset$.

6.1.3.2.2 Partitionierung des Evidenzenraumes

Die oben beschriebene Methode der “Verfeinerung” der Beobachtungsfunktion durch Hinzufügen zusätzlicher Klauseln behebt zwar das Problem von Guan und Bell der Nichtanwendbarkeit bestimmter Regeln, führt aber neben den bereits angesprochenen Problemen im Extremfall zu $(2^{|\Theta|} - 1)$ Beobachtungsregeln – je eine pro möglicher Evidenz – mit jeweils mehreren Klauseln.

Die zweite Möglichkeit, die Regeln ihrer intuitiven Bedeutung entsprechend zu formulieren, wäre es, in den Prämissen die Formeln $\mathbf{K}_e A$ durch $\mathbf{K}A$ zu ersetzen. Dies

entspricht der intendierten Semantik der Regeln (“produziere die Konklusion, sobald die Prämisse bekannt ist”) und reduziert die benötigte Anzahl der Beobachtungsregeln auf ein Minimum. Allerdings widerspricht dieses Vorgehen Satz 5.3.1, in dem die Berechnung der Hypothesenstärke gemäß Definition 5.2.3 als spezielle Instanz der Regel der totalen Wahrscheinlichkeit charakterisiert wird.³ Das Problem liegt darin, daß die Mengen $\mathbf{k}(A)$ der die Formeln $\mathbf{K}A$ erfüllenden möglichen Welten *keine* Partition des Universums bilden, wie dies die Mengen $\mathbf{e}(A)$ im Falle der Prämissen $\mathbf{K}_e A$ tun.

Es existiert ein Mittelweg zwischen beiden Alternativen, der einerseits die Anzahl der zusätzlich benötigten Regeln beschränkt, andererseits eine Approximation des \mathbf{K} -Operators in den Prämissen induziert. Die grundlegende Idee dabei ist, Evidenzen mit äquivalentem Verhalten in Hinsicht auf den Hypothesenraum zusammenzufassen und für jede dieser Klassen nur jeweils *eine* Regel aufzustellen.

Eine Aktion A , repräsentiert durch eine Teilmenge $A \subseteq \Theta$ des Evidenzenraumes, unterstützt als Evidenz eine Planhypothese H , repräsentiert durch eine Teilmenge $H \subseteq \mathcal{P}_0$ des Hypothesenraumes, d.h. $A \sim H$, genau dann, wenn

- A in der Dekomposition von H auftritt: $A \in A_H$ oder
- A durch eine Aktion A' abstrahiert wird, die ihrerseits zur Dekomposition von H gehört: $A \subseteq A'$, $A' \in A_H$.

Anmerkung: Diese Relation zwischen Aktionen und Hypothesen wird bei der Initialisierung der Beobachtungsregeln gemäß (6.2) bzw. (6.3) mit der Einführung zusätzlicher Klauseln zur expliziten Repräsentation partieller Unwissenheit (beispielsweise mit Konklusion \mathcal{P}_0) erweitert.

Die Relation \sim induziert nun zusammen mit der Abstraktionsrelation auf dem Evidenzenraum eine Einteilung in Klassen von Aktionen, die sich als Evidenz äquivalent verhalten.

Definition 6.1.3 (Δ -Äquivalenz)

$A_1, A_2 \subseteq \Theta$ heißen Δ -äquivalent, falls

- $A_1 \subseteq A_2$,
- $A_1 \sim H$ genau dann, wenn $A_2 \sim H$ für alle $H \subseteq \mathcal{P}_0$ und
- $C_H(A_1) = C_H(A_2)$ für alle $H \in G_\Delta(A_1) \cup G_\Delta(A_2)$

Dabei stellt die dritte Bedingung sicher, daß die Constraints zwischen den Aktionen A_1 und A_2 und allen Plänen, in deren Dekomposition sie auftreten, identisch sind. Dadurch wird erreicht, daß beide in diesen Plänen untereinander austauschbar sind.

³In diesem Fall wäre es auch unklar, welche Regel angewandt werden soll, da mit $\mathbf{K}A$ auch gleichzeitig $\mathbf{K}A'$ für alle $A \Rightarrow A'$ gilt.

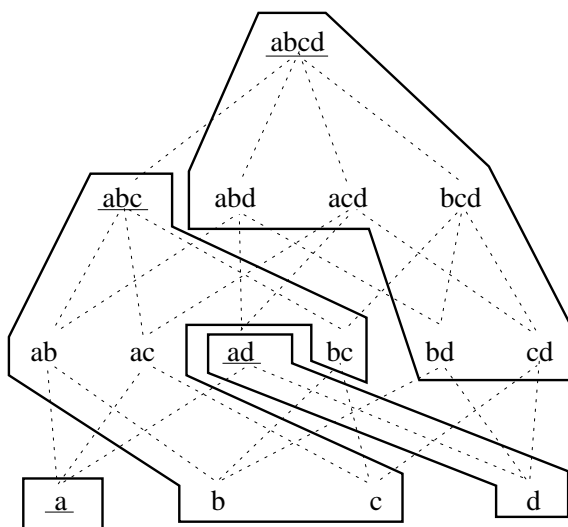


Abbildung 6.3: Partitionierung durch $\mathcal{C}(\Theta)$.

Es genügt nun, für jede solche Klasse *eine* Beobachtungsregel aufzustellen und die gegebenen Beobachtungen entsprechend zu kodieren. Sei dazu $D = \{A_1, \dots, A_l\} \subseteq 2^\Theta$ die Menge aller Aktionen, die in den Dekompositionen der aktuellen Planhierarchie auftreten.

Definition 6.1.4 (Δ -Partitionierung)

In dieser Situation heißt die kleinste Menge

$$\mathcal{C}(\Theta) = \{A_1, \dots, A_m\} \subseteq 2^\Theta$$

- mit
- $D \subseteq \mathcal{C}(\Theta)$,
 - $\mathcal{C}(\Theta)$ ist unter der Durchschnittsbildung abgeschlossen, enthält also mit A_i und A_j auch $A_i \cap A_j$ (mit Ausnahme der leeren Menge \emptyset) und
 - $\Theta \in \mathcal{C}(\Theta)$

eine Δ -Partitionierung von Θ . Ist der zugrundeliegende Evidenzenraum Θ eindeutig bestimmt, so wird meist nur \mathcal{C} geschrieben.

Anmerkung: Später wird jede Menge $\{A_1, \dots, A_m\} \subseteq 2^\Theta$, die unter der Durchschnittsbildung abgeschlossen ist und Θ enthält, als Δ -Partitionierung bezeichnet.

Jedes Element $A \in \mathcal{C}(\Theta)$ repräsentiert die Klasse aller mit A Δ -äquivalenten Teilmengen $A' \subseteq A$. Die Forderung $\Theta \in \mathcal{C}(\Theta)$ stellt sicher, daß *alle* Teilmengen des Evidenzenraumes von einer solchen Klasse erfaßt werden. In den meisten Fällen enthält die Klasse von Θ all diejenigen Aktionen A mit $G_\Delta(A) = \emptyset$ (vergleiche dazu auch (6.4)).

Beispiel 6.1.2 Seien ein Evidenzenraum $\Theta = \{a, b, c, d\}$ und ein Hypothesenraum \mathcal{P}_0 gegeben (siehe Abbildung 6.3). Die einzelnen Teilmengen sind durch Angabe ihrer Elemente dargestellt (d.h. abc steht für die Menge $\{a, b, c\}$). In den Dekompositionen der Elemente von \mathcal{P}_0 treten ausschließlich die Aktionen ad und abc auf. Als Δ -Partitionierung ergibt sich

$$\mathcal{C}(\Theta) = \{a, ad, abc, abcd\}$$

Alle Evidenzen, die spezieller sind als abc , etwa ab , können nun lediglich auf diejenigen Hypothesen verweisen, in denen bereits abc auftritt. Als Evidenz betrachtet, sind sie also alle äquivalent. Eine Ausnahme dazu bildet a . Wird diese Aktion beobachtet, so müssen Schlüsse sowohl auf die mit abc assoziierten Hypothesenmengen $G_\Delta(\{a, b, c\})$ möglich sein, als auch auf diejenigen in $G_\Delta(\{a, d\})$.

Definition 6.1.5 (Operator $\mathbf{K}_{\mathcal{C}(\Theta)}$)

In der beschriebenen Situation heißt der Modaloperator $\mathbf{K}_{\mathcal{C}(\Theta)}$ mit

$$\mathbf{K}_{\mathcal{C}(\Theta)}A = \bigvee_{\substack{A' : A' \Rightarrow A \\ \exists A'' \in \mathcal{C}(\Theta) : A'' \Rightarrow A \\ A' \Rightarrow A''}} \mathbf{K}_e A'$$

der mit $\mathcal{C}(\Theta)$ assoziierte Wissensoperator, wobei wiederum Teilmengen von Θ und die entsprechenden Sätze des logischen Evidenzenraumes miteinander identifiziert wurden. Wenn die Δ -Partitionierung eindeutig bestimmt ist, wird meist einfach $\mathbf{K}_{\mathcal{C}}$ geschrieben.

$\mathbf{K}_{\mathcal{C}(\Theta)}A$ mit $A \in \mathcal{C}(\Theta)$ bedeutet somit, daß der Agent zwar A , aber keinen stärkeren Satz aus $\mathcal{C}(\Theta)$ kennt. Die Definition 4.1.16 der Menge der eine Formel erfüllenden möglichen Welten kann somit erweitert werden für diesen abgeleiteten Operator:

$$\mathbf{T}(\mathbf{K}_{\mathcal{C}(\Theta)}A) = \mathbf{e}_{\mathcal{C}(\Theta)}(A) = \bigcup_{\substack{A' : A' \Rightarrow A \\ \exists A'' \in \mathcal{C}(\Theta) : A'' \Rightarrow A \\ A' \Rightarrow A''}} \mathbf{e}(A') \quad (6.5)$$

Anmerkungen:

1. Ist $\mathcal{C}(\Theta) = 2^\Theta$, so wird der Operator $\mathbf{K}_{\mathcal{C}(\Theta)}$ äquivalent zu \mathbf{K}_e
2. Sind die Elemente $A_i, i = 1, \dots, n$, von $\mathcal{C}(\Theta) = \{A_1, \dots, A_n, \Theta\}$ paarweise disjunkt, so gilt $\mathbf{K}_{\mathcal{C}(\Theta)}A_j \Leftrightarrow \mathbf{K}A_j$.
3. Ist hingegen $\mathcal{C}(\Theta) = \{\Theta\}$, so gilt $\mathbf{K}_{\mathcal{C}(\Theta)}\Theta \Leftrightarrow \mathbf{K}\Theta$.
4. Regelklauseln werden von nun ab mit Konditionalen der Form

$$\mathbf{K}_e H \mid \mathbf{K}_{\mathcal{C}(\Theta)} A$$

identifiziert.

Bisher wurden Evidenzen stets als Basiswahrscheinlichkeiten c auf dem Evidenzenraum repräsentiert. Nach den Ergebnissen von Abschnitt 5.3 entsprechen diese Werte $c(A)$ den Wahrscheinlichkeiten $P(\mathbf{K}_e A)$ bzw. $P(\mathbf{e}(A))$ im zugehörigen Satzraum bzw. der epistemischen Algebra des zugehörigen Universums. Aufgrund der veränderten Form der die Regeln repräsentierenden Konditionale werden Evidenzen von nun ab durch spezielle Basiswahrscheinlichkeiten $c_{\mathcal{C}(\Theta)}$ repräsentiert:

Definition 6.1.6 (induzierte Basiswahrscheinlichkeit)

Sei $c : 2^\Theta \rightarrow [0, 1]$ eine Basiswahrscheinlichkeit, $\mathcal{C}(\Theta) = \{A_1, \dots, A_n, \Theta\} \subseteq 2^\Theta$ eine Δ -Partitionierung von Θ . Dann heißt $c_{\mathcal{C}(\Theta)}$ mit

$$c_{\mathcal{C}(\Theta)} : 2^\Theta \rightarrow [0, 1]$$

$$A \mapsto \begin{cases} \sum_{A' \subseteq A} c(A') - \sum_{A' \subset A} c_{\mathcal{C}(\Theta)}(A'), & A \in \mathcal{C}(\Theta) \\ 0, & \text{sonst} \end{cases}$$

die durch c und $\mathcal{C}(\Theta)$ induzierte Basiswahrscheinlichkeit.

Anmerkungen:

1. Die Fokalelemente von $c_{\mathcal{C}(\Theta)}$ sind gerade die Elemente von $\mathcal{C}(\Theta)$.
2. Nach Gleichung (6.5) gilt

$$c_{\mathcal{C}(\Theta)}(A) = P(\mathbf{K}_{\mathcal{C}(\Theta)} A) = P(\mathbf{T}(\mathbf{K}_{\mathcal{C}(\Theta)} A)) = P(\mathbf{e}_{\mathcal{C}(\Theta)}(A)). \quad (6.6)$$

3. Gilt $\mathcal{C}(\Theta) = 2^\Theta$, so ist $c_{\mathcal{C}(\Theta)} = c$.

Die Berechnung der Hypothesenstärke kann somit neu definiert werden.

Definition 6.1.7 (Hypothesenstärke)

Seien $c : 2^\Theta \rightarrow [0, 1]$ eine Basiswahrscheinlichkeit auf dem Evidenzenraum, $\mathcal{C}(\Theta)$ eine Δ -Partitionierung von Θ und $R = \{s_A \mid \Theta \supseteq A \in \mathcal{C}(\Theta)\}$ eine Regel. Dann heißt die Funktion

$$r : 2^{\mathcal{P}_0} \rightarrow [0, 1]$$

$$H \mapsto \sum_{A \in \mathcal{C}(\Theta)} s_A(H) c_{\mathcal{C}(\Theta)}(A)$$

die durch die Evidenz c und Regel R induzierte Hypothesenstärke.

Im Gegensatz zur Definition 5.2.3 der Hypothesenstärke durch Guan und Bell, in der über *alle* Teilmengen von Θ summiert werden muß, werden hier zur Berechnung von r lediglich $|\mathcal{C}(\Theta)|$ Summanden benötigt. Definition 5.2.3 stellt somit den Spezialfall mit $\mathcal{C}(\Theta) = 2^\Theta$ dar.

Diese Berechnungsvorschrift kann ebenso wie die ursprüngliche Formulierung aus Definition 5.2.3 als Instanz der Regel der totalen Wahrscheinlichkeit formal gerechtfertigt werden, wobei in Gleichung (5.19) von Satz 5.3.1 lediglich die Summanden $P(\mathbf{K}_e H | \mathbf{K}_e E) P(\mathbf{K}_e E)$ durch $P(\mathbf{K}_e H | \mathbf{K}_{\mathcal{C}(\Theta)} A) P(\mathbf{K}_{\mathcal{C}(\Theta)} A)$ zu ersetzen sind. Die Menge der Erfüllungsmengen $\mathbf{e}_{\mathcal{C}(\Theta)}(A)$ der Formeln $\mathbf{K}_{\mathcal{C}(\Theta)} A$ bilden ebenso wie die zu den Prämissen $\mathbf{K}_e(A)$ gehörigen $\mathbf{e}(A)$ eine Partition des zugrundeliegenden Universums der möglichen Welten, wodurch die Anwendung der Regel der totalen Wahrscheinlichkeit zulässig ist:

Lemma 6.1.1 *Für eine Δ -Partitionierung $\mathcal{C}(\Theta) = \{A_1, \dots, A_n, \Theta\} \subseteq 2^\Theta$ bildet die Menge der die Formeln $\mathbf{K}_{\mathcal{C}(\Theta)} A$ mit $A \in \mathcal{C}(\Theta)$ erfüllenden Teilmengen $\mathbf{e}_{\mathcal{C}(\Theta)}(A)$ des Universums $\mathcal{U}(\mathcal{S}_{ev}^+)$ eine Partition von $\mathcal{U}(\mathcal{S}_{ev}^+)$.*

Beweis: Seien $A, B \in \mathcal{C}(\Theta)$ und $\mathbf{e}(X) \subseteq \mathbf{e}_{\mathcal{C}(\Theta)}(A) \cap \mathbf{e}_{\mathcal{C}(\Theta)}(B)$. Gemäß Definition 6.1.4 ist dann auch $A \cap B \in \mathcal{C}(\Theta)$ (aus logischer Sicht gilt dabei $X \Rightarrow A, X \Rightarrow B$ und $X \Rightarrow A \wedge B$). Damit gilt aber $\mathbf{e}(X) \not\subseteq \mathbf{e}_{\mathcal{C}(\Theta)}(A)$ und $\mathbf{e}(X) \not\subseteq \mathbf{e}_{\mathcal{C}(\Theta)}(B)$. Sei $\mathbf{e}(X) \subset \mathcal{U}(\mathcal{S}_{ev}^+)$. Falls $\mathbf{e}(X) \not\subseteq \mathbf{e}_{\mathcal{C}(\Theta)}(A_j)$ für alle $j = 1, \dots, n$, so gilt $\mathbf{e}(X) \subseteq \mathbf{e}_{\mathcal{C}(\Theta)}(\Theta)$. \square

Satz 6.1.1 *Die Hypothesenstärke*

$$r(H) = \sum_{A \in \mathcal{C}(\Theta)} s_A(H) c_{\mathcal{C}(\Theta)}(A)$$

nach Definition 6.1.7 ist eine Wahrscheinlichkeitsfunktion auf der epistemischen Algebra $\hat{\Omega}_E$ und induziert daher eine eindeutig bestimmte Wahrscheinlichkeitsfunktion auf Ω_E^{hyp} .

Beweis: Der Beweis entspricht demjenigen von Satz 5.3.1, wobei an den entsprechenden Stellen \mathbf{K}_e durch $\mathbf{K}_{\mathcal{C}(\Theta)}$, \mathbf{e} durch $\mathbf{e}_{\mathcal{C}(\Theta)}$ und $\hat{\mathbf{e}}_{ev}$ durch die entsprechenden marginalen epistemischen Mengen $\hat{\mathbf{e}}_{ev, \mathcal{C}(\Theta)}$ zu ersetzen sind.

$$r(H) = \sum_{A \subseteq \Theta} s_A(H) c_{\mathcal{C}(\Theta)}(A) \quad (6.7)$$


$$= \sum_{A \in \Phi(\mathcal{S}_{ev})} P(\mathbf{K}_e H | \mathbf{K}_{\mathcal{C}(\Theta)} A) P(\mathbf{K}_{\mathcal{C}(\Theta)} A) \quad (6.8)$$

$$= \sum_{\mathbf{e}_{\mathcal{C}(\Theta)}(A) \subseteq \mathcal{U}(\mathcal{S}^+)} P(\mathbf{e}(H) | \mathbf{e}_{\mathcal{C}(\Theta)}(A)) P(\mathbf{e}_{\mathcal{C}(\Theta)}(A)) \quad (6.9)$$

$$= \sum_{\hat{\mathbf{e}}_{ev, \mathcal{C}(\Theta)}(A) \subseteq \mathcal{U}(\mathcal{S}^+)} P(\mathbf{e}(H) | \hat{\mathbf{e}}_{ev, \mathcal{C}(\Theta)}(A)) P(\hat{\mathbf{e}}_{ev, \mathcal{C}(\Theta)}(A)) \quad (6.10)$$

$$= P(\mathbf{e}(H)) \quad (6.11)$$

$$= P(\hat{\mathbf{e}}_{hyp}(H)) \quad (6.12)$$

Abbildung 6.4: Effekt einer Δ -Partitionierung $\mathcal{C}(\Theta)$.

(6.9) = (6.10): siehe Lemma 5.3.1

(6.10) = (6.11): siehe Lemma 6.1.1

□

Beispiel 6.1.3 Für den Fall der Planhierarchie aus Abbildung 6.2 ergibt sich eine Δ -Partitionierung

$$\mathcal{C}(\Theta) = \left\{ \begin{array}{l} \{ \text{GoToKitchen} \}, \\ \{ \text{Boil} \}, \\ \{ \text{MakeSpaghetti}, \text{MakeFettucini} \}, \\ \{ \text{MakeSauce} \}, \\ \Theta \}. \end{array} \right.$$

Die *Verfeinerung* der aus einer Planhierarchie gewonnenen Beobachtungsfunktion gemäß dem in Abschnitt 6.1.3.2.1 beschriebenen Verfahren ermöglichte die Lösung des beim System von Guan und Bell (siehe Abschnitt 5.2) auftretenden Problems der Nichtanwendbarkeit einer Regel bei zu spezifischer Evidenz. Die Folge war eine große Anzahl von Regelklauseln, deren Semantik nicht mit der intuitiven Interpretation einer Regel übereinstimmt (wie dies auch bereits in der ursprünglichen, in [Guan und Bell, 1991] beschriebenen Version der Fall war). Die Einführung abgeleiteter Regelklauseln mit spezifischeren Prämissen erlaubt jeweils die Anwendung der *speziellsten* vorhandenen Regel.

Diese Eigenschaft bleibt bei der in diesem Abschnitt eingeführten Technik der Δ -Partitionierung erhalten. Neben der Reduzierung der Anzahl der benötigten Regelklauseln – und damit auch der Summanden in der Berechnung der Hypothesenstärke – erlaubt sie eine Strukturierung des Evidenzenraumes und verleiht den einzelnen Regelklauseln eine Semantik, die zumindest in Spezialfällen exakt der intuitiven Deutung einer Regel (mit Prämisse **KA**) entspricht.

Abbildung 6.4 verdeutlicht nochmals den Effekt der Δ -Partitionierung, der Teile des Evidenzenraumes zusammenfaßt und diesen Hypothesen zuordnet.

Anmerkung: Die in diesem Abschnitt eingeführte Technik ist nur initial anwendbar, d.h. solange keine Regelgewichte für die einzelnen Evidenzen verfügbar sind. Liegt aber bereits statistische Information in Form bedingter Wahrscheinlichkeiten vor, so ist das Kriterium der Δ -Äquivalenz nicht ausreichend, die Zusammenfassung der entsprechenden Regeln zu rechtfertigen.

6.1.3.3 Berücksichtigung von Constraints – Partielle Regelanwendung

Wie zu Beginn des Abschnitts 6.1.3.2 bereits angedeutet, wurden die zu einer Plandekomposition $\langle p, A_p, C_p \rangle$ gehörigen Constraints C_p bei der bisherigen Behandlung der Beobachtungsregeln vernachlässigt. Tatsächlich spielen sie jedoch eine entscheidende Rolle, da eine Aktion $a \in A_p$, die zwar als notwendiger Schritt von p vorgesehen ist, aber beispielsweise mit unpassendem Parameter oder zum “falschen” Zeitpunkt ausgeführt wird, *nicht* als Evidenz zugunsten der Hypothese p betrachtet werden kann.


Notation: Die Menge aller eine Aktion a mit einem Plan p verbindenden Constraints wird mit $C_p(a) \subseteq C_p$ bezeichnet.

Die Verifikation der in $C_p(a)$ enthaltenen Bedingungen bildet einen Schwerpunkt des eigentlichen Planerkennungsprozesses und kann neben Typ- oder Gleichheitsüberprüfungen für Objekte auch temporales Schließen, allgemeine Deduktionen bzw. Anfragen an ein Anwendungssystem beinhalten. Dieser Prozeß der Entscheidung der Gültigkeit von Constraints wird hier nicht näher betrachtet. Da das hier beschriebene System unabhängig von speziellen Eigenheiten der Planerkenner als Bewertungsmechanismus mit diesen kombinierbar sein soll, wird angenommen, daß neben der aktuell beobachteten Aktion a – als Evidenz, wie sie bisher betrachtet wurde – auch die notwendige Information zur Verifikation von $C_p(a)$ geliefert werden. Die spezielle Form und die Genauigkeit, mit der dies geschieht, wird weiter unten diskutiert.

6.1.3.3.1 Typisierung der Regeln

Zunächst soll geklärt werden, welche verschiedenen Vorgehensweisen es bei der Behandlung verletzter Constraints bei der Regelanwendung gibt. Dies führt zu einer Einteilung in verschiedene Klassen von Regeln, die es erlaubt, durch einfache Angabe des Typs einer Regel deren gesamtes Verhalten im Konfliktfall eindeutig zu spezifizieren. Als Basis für die weitere Diskussion seien die beiden in Abbildung 6.5 dargestellten Regeln gegeben. Dabei sei die Regel R_1 mit Prämisse A_1 direkt aus einer Planhierarchie ohne Zuhilfenahme zusätzlichen Wissens gewonnen worden (siehe Abschnitt 6.1.3.2), während die von A_2 ausgehende Regel R_2 aus dem Benutzermodell stammt, so daß die Regelgewichte v_i zusätzliches Wissen repräsentieren.

Eine der wesentlichen Eigenschaften der Dempster-Shafer Theorie ist die Möglichkeit, bei unzureichendem Wissen Teile der Evidenzmasse möglichst unspezifischen Hypothesen so zuzuordnen, daß erst zusätzliche Information den Fluß dieser Masse

Abbildung 6.5: Zwei prototypische Beobachtungsregeln R_1 und R_2 .

zu spezifischeren Hypothesen auslöst. Im Falle der Beobachtungsregeln in der Planerkennung bedeutet dies folgendes: Wird eine Aktion a beobachtet, die zwar zur Dekomposition einer Hypothese p gehört, jedoch nicht alle zugehörigen Constraints erfüllt (a wird etwa zum falschen Zeitpunkt ausgeführt), so kann a nicht mehr als direkte Evidenz für ein Auftreten von p betrachtet werden. Ist p nun ein Plan, der durch dieses "falsche" Vorkommen von a *nicht* vollständig unmöglich wird, so besteht keine Veranlassung, p aus dem Hypothesenraum zu entfernen und das entsprechende Regelgewicht z.B. dem Komplement \bar{p} zuzuweisen. Vielmehr erlaubt es die Dempster-Shafer Theorie in diesem Fall, den entsprechenden numerischen Wert der allgemeinsten Hypothesen \mathcal{P}_0 zuzuordnen, wodurch zum Ausdruck kommt, daß die vorliegende Evidenz a mit ihren aktuellen Parametern keine der möglichen Hypothesen direkt unterstützt. Dieser Sachverhalt kann durch eine entsprechende Modifikation der betroffenen Regeln repräsentiert werden.

Im Falle der beiden Regeln R_1 und R_2 ergibt sich folgende Situation. Sei $H_1 \in G_\Delta(A_1)$ die einzige Hypothese, für die $C_{H_1}(A_1)$ und $C_{H_1}(A_2)$ verletzt sind. Dann ergeben sich daraus die folgenden Modifikationen:

$$\begin{array}{l}
 A_1 \begin{array}{l} \nearrow \\ \searrow \end{array} \begin{array}{l} \bigcup_{H_1 \neq H \in G_\Delta(A_1)} M(H) \langle c_0 - c_0 \cdot x \rangle \\ \mathcal{P}_0 \langle 1 - (c_0 - c_0 \cdot x) \rangle \end{array} \quad (6.13)
 \end{array}$$

für R_1 und

$$\begin{array}{l}
 A_2 \begin{array}{l} \nearrow \\ \searrow \\ \searrow \\ \searrow \end{array} \begin{array}{l} H_2 \langle v_2 \rangle \\ \vdots \\ H_n \langle v_n \rangle \\ \mathcal{P}_0 \langle v_{\mathcal{P}_0} + v_1 \rangle \end{array} \quad (6.14)
 \end{array}$$

im Fall von R_2 . Dabei ist x im Fall von R_1 so gewählt, daß es die relative Größe von

H_1 im Vergleich zu $G_\Delta(A_1)$ widerspiegelt. Der genaue Wert für x ist

$$x = \frac{|M(H_1)|}{\left| \bigcup_{H \in G_\Delta(A_1)} M(H) \right|}. \quad (6.15)$$

Anmerkungen:

1. Im allgemeinen Fall gilt folgendes. Sei $H^- \subseteq G_\Delta(A_1)$ die Menge aller Hypothesen, deren Constraints bzgl. A_1 verletzt sind. Dann ergibt sich für x

$$x = \frac{\left| \bigcup_{H \in H^-} M(H) \right|}{\left| \bigcup_{H \in G_\Delta(A_1)} M(H) \right|}.$$

2. Sind die Constraints *aller* Hypothesen aus $G_\Delta(A_1)$ verletzt, so erhält x den Wert 1, und die durch die Regel induzierte Hypothesenstärke wird zur leeren Basiswahrscheinlichkeit.

Beide modifizierten Regeln weisen somit den ursprünglich für H_1 vorgesehenen Anteil der Regelstärke an \mathcal{P}_0 , die Menge aller möglichen Hypothesen zu, wodurch H_1 nicht mehr direkt unterstützt, die Plausibilität aller Pläne jedoch gleichermaßen erhöht wird.

Befindet man sich hingegen in einer Anwendung, in der die verschiedenen Pläne so detailliert beschrieben sind, daß jede Abweichung zur endgültigen Ablehnung der entsprechenden Hypothese führt, so ist dies mit einer Einschränkung des Hypothesenraumes auf das Komplement dieser Hypothesenmenge gleichzusetzen. Die entsprechenden Modifikationen sind dann

$$\begin{array}{l}
 A_1 \begin{cases} \nearrow \bigcup_{H \in G_\Delta(A_1)} M(H) \setminus M(H_1) \langle c_0 \rangle \\ \searrow \mathcal{P}_0 \setminus M(H_1) \langle 1 - c_0 \rangle \end{cases}
 \end{array} \quad (6.16)$$

für R_1 und

$$\begin{array}{l}
 A_2 \begin{cases} \nearrow H_2 \langle \frac{v_2}{1-v_1} \rangle \\ \quad \quad \quad \vdots \\ \searrow H_n \langle \frac{v_n}{1-v_1} \rangle \\ \quad \quad \quad \mathcal{P}_0 \setminus M(H_1) \langle \frac{v_{\mathcal{P}_0}}{1-v_1} \rangle \end{cases}
 \end{array} \quad (6.17)$$

für R_2 .

Anmerkungen:

1. In der Modifikation (6.13) verweist die erste Klausel *nicht* auf $G_{\Delta}(A_1) \setminus M(H_1)$, da ansonsten Hypothesen, die in anderen Mengen $M(H_i)$ mit $H_i \in G_{\Delta}(A_1)$ enthalten sind, verlorengehen könnten.
2. Mitunter ist es sinnvoll, Regeln mit dem Aussehen von R_2 in Regeln vom Typ R_1 abzuwandeln, wobei $c_0 = v_1 + \dots + v_n$ ist. Möglicher Grund dafür ist eine Erhöhung der Effizienz etwa in zeitkritischen Anwendungen, da die entsprechende Regelstärke als Basiswahrscheinlichkeit nur noch zwei Fokalelemente aufweist, wodurch die Kombination vereinfacht wird (siehe dazu auch Abschnitt 6.5). Die Modifikation solcher Regeln erfolgt gemäß

$$\begin{array}{rcl}
 A_1 & \begin{array}{l} \nearrow \\ \searrow \end{array} & \begin{array}{l} \bigcup_{H \in G_{\Delta}(A_1) \setminus H_1} M(H) \quad \langle c_0 - v_1 \rangle \\ \mathcal{P}_0 \quad \langle 1 - c_0 + v_1 \rangle \end{array} \quad (6.18)
 \end{array}$$

bzw. gemäß

$$\begin{array}{rcl}
 A_1 & \begin{array}{l} \nearrow \\ \searrow \end{array} & \begin{array}{l} \bigcup_{H \in G_{\Delta}(A_1) \setminus H_1} M(H) \quad \langle c_0 - v_1 \rangle \\ \mathcal{P}_0 \setminus M(H_1) \quad \langle 1 - c_0 + v_1 \rangle \end{array} \quad (6.19)
 \end{array}$$

falls die Elemente aus $M(H_1)$ endültig verworfen werden sollen.

3. Existieren Pläne, die ein Vorkommen von A_1 bzw. A_2 explizit ausschließen, so ist in den o.a. Regeln R_1 und R_2 sowie allen Modifikationen jeweils \mathcal{P}_0 durch die Hypothesenmenge \mathcal{P}_{A_i} , $i = 1, 2$, aller mit A_i verträglichen Pläne zu ersetzen.
4. Ist in R_2 der Wert $v_{\mathcal{P}_0} = 0$ und sind die Constraints *sämtlicher* Hypothesen H_1, \dots, H_n verletzt, so ist die Modifikation gemäß (6.17) undefiniert. Die Verwendung dieser Strategie unterliegt somit gewissen Einschränkungen, die bei der Entscheidung für eine bestimmte Regelklasse berücksichtigt werden müssen.

Der allgemeinste Fall der Regelmodifikation setzt die Angabe einer Menge alternativer Hypothesen voraus, die im Konfliktfall die Rolle der betroffenen Hypothesen in der Regel besetzen. Sind für R_2 beispielsweise $\{H'_1, \dots, H'_n\}$ als Alternativen gegeben,

Bezeichnung	ID	UD	IB	UB	AD	AB	US
Modifikation	(6.13)	(6.14)	(6.16)	(6.17)	(6.18)	(6.19)	(6.20)

Tabelle 6.1: Überblick über die Regelklassen.

so führt dies in der gegebenen Situation zur Modifikation

$$\begin{array}{c}
 A_2 \begin{array}{l} \nearrow \\ \nearrow \\ \vdots \\ \searrow \\ \searrow \end{array} \begin{array}{l} H'_1 \langle v_1 \rangle \\ H_2 \langle v_2 \rangle \\ \vdots \\ H_n \langle v_n \rangle \\ \mathcal{P}_0 \langle v_{\mathcal{P}_0} \rangle \end{array} \quad (6.20)
 \end{array}$$

in der die Hypothese H_1 durch ihre Alternative H'_1 ersetzt wurde. Alle anderen Modifikationen können als Spezialfall von (6.18) betrachtet werden.

Alle in diesem Abschnitt vorgestellten Regelmodifikationen repräsentieren das Verhalten der Regeln R_1 und R_2 , wenn diese nur partiell anwendbar sind, d.h. wenn eine ihrer Klauseln in der aktuellen Situation eine ungültige Verbindung zwischen Evidenz und Hypothese darstellt. Die (vollständige) Anwendung der modifizierten Versionen entspricht dem intendierten Verhalten bei partieller Anwendung der ursprünglichen Regeln. Sind mehrere Hypothesen H_i von verletzten Constraints betroffen, so müssen die beschriebenen Modifikationen für alle entsprechenden Regelklauseln durchgeführt werden.

Notationen: Für die den obigen Modifikationen entsprechenden Klassen von Regeln werden nun Bezeichnungen der Form xy eingeführt, wobei $x \in \{I, U, A\}$ und $y \in \{D, B, S\}$. $x = I$ steht für eine in dieser Form initiierte Regel (im Beispiel R_1), während U für eine dem Benutzermodell (*user model*) entnommene Regel steht. A bezeichnet eine approximierte Regel, die die Basis für die Modifikation (6.18) darstellt. Die zweite Stelle charakterisiert die gewählte Strategie der Konfliktauflösung, wobei D für das mit der Dempster-Shafer Theorie konforme Vorgehen gemäß (6.13), (6.14) und (6.18) steht, B die ‘‘Bayessche’’ Variante mit Ausschluß der betroffenen Hypothesen und Normalisierung (siehe (6.16), (6.17) und 6.19), die nur bedingt verwendet werden kann (siehe Anmerkungen auf Seite 122) und S die allgemeine Version mit spezifizierten Alternativen gemäß (6.20) bezeichnet. Tabelle 6.1 gibt einen Überblick.

Definition 6.1.8 (revidierte Regelstärke)

Seien $A \subseteq \Theta$, s_A die mit ihr assoziierte Regelstärke (siehe Definition 5.1.3) und

o.B.d.A. $H_1, \dots, H_l \in G_\Delta(A) = \{H_1, \dots, H_n\}$ so, daß $C_{H_i}(A)$ verletzt ist, $i = 1, \dots, l$. Die bzgl. H_1, \dots, H_l revidierte Regelstärke der gemäß des oben beschriebenen Vorgehens modifizierten Regel wird mit $\tilde{s}_A^{C_1, \dots, C_n}$ bezeichnet, wobei $C_i = \neg C_{H_i}(A)$ für $1 \leq i \leq l$ und $C_i = C_{H_i}(A)$ sonst. Ist die Menge der betroffenen Hypothesen klar, wird einfach \tilde{s}_A geschrieben.

6.1.3.3.2 Formale Behandlung

Im vorhergehenden Abschnitt wurde der Übergang von einer Regelstärke s_A zur revidierten Version \tilde{s}_A rein prozedural betrachtet. Das formale Verhältnis beider Funktionen zueinander, eine Semantik für \tilde{s}_A sowie eine Untersuchung der Auswirkungen auf die induzierte Hypothesenstärke sind Gegenstand der folgenden Ausführungen.

Bisher entsprach eine Regelklausel einem Konditional $(\mathbf{K}_e H | \mathbf{K}_{C(\Theta)} A)$, dessen numerisches Gewicht der bedingten Wahrscheinlichkeit $P(\mathbf{K}_e H | \mathbf{K}_{C(\Theta)} A)$ entsprach. Modelliert man die zugehörigen Constraints als eine Boolesche Variable $C_H(A)$, so liegt es nahe, die Beobachtungsregeln als

$$(\mathbf{K}_e H | \mathbf{K}_{C(\Theta)} A, \mathbf{K} C_H(A))$$

zu formulieren. Für den Fall der Regel R_2 aus Abbildung 6.5 und ihrer Modifikation gemäß (6.14) bedeutet dies etwa

$$\begin{aligned} s_{A_2}(H_1) &= P(\mathbf{K}_e H_1 | \mathbf{K}_{C(\Theta)} A_2, \mathbf{K} C_{H_1}(A_2)) = v_1 \\ \tilde{s}_{A_2}(H_1) &= P(\mathbf{K}_e H_1 | \mathbf{K}_{C(\Theta)} A_2, \neg \mathbf{K} C_{H_1}(A_2)) = 0. \end{aligned}$$

Auf der Basis dieser $C_H(A)$ läßt sich eine logische Sprache definieren, deren Elemente Aussagen über Constraints zwischen Aktionen und Hypothesen darstellen.

Definition 6.1.9 (Constraintsatzraum)

Sei $C_{H_1}(A), \dots, C_{H_n}(A), C_{\mathcal{P}_0}(A)$ die Menge aller die Aktion A betreffenden Constraintvariablen. Dann wird der gemäß Definition 4.1.1 über dem Alphabet

$$\mathcal{A} = \{C_{H_1}(A), \dots, C_{H_n}(A), C_{\mathcal{P}_0}(A)\}$$

gebildete Satzraum $\mathcal{S}_{C,A}$ als *Constraintsatzraum bzgl. A* bezeichnet. Der alle $\mathcal{S}_{C,A}$ umfassende (*globale*) *Constraintsatzraum* wird mit \mathcal{S}_C bezeichnet.

Definition 6.1.10 (Constraintalgebra)

Die mit $\mathcal{S}_{C,A}$ assoziierte Lindenbaumalgebra $\mathcal{L}(\mathcal{S}_{C,A})$ (die Boolesche Algebra mit Operationen \wedge, \vee und \neg auf den Äquivalenzklassen von $\mathcal{S}_{C,A}/\Leftrightarrow$) wird als die *Constraintalgebra von A* bezeichnet. Die kleinste Algebra CA , die alle Algebren $\mathcal{L}(\mathcal{S}_{C,A})$ für $A \subseteq \Theta$ umfaßt, ist die (*globale*) *Constraintalgebra*.

Anmerkungen:

1. Die Atome von $\mathcal{L}(\mathcal{S}_{C,A})$ können in der Form

$$C_1 \wedge \dots \wedge C_n \wedge C_{\mathcal{P}_0}$$

dargestellt werden, wobei $C_i \in \{C_{H_i}(A), \neg C_{H_i}(A)\}$ gilt. Die Menge aller dieser Atome wird mit $At(\mathcal{S}_{C,A})$ bezeichnet.

2. Die in Kapitel 4 eingeführten Begriffe der möglichen Welten, der Unterstützungs- und Wahrheitsmengen und der epistemischen und Wahrheitsalgebren können hier entsprechend auf $\mathcal{L}(\mathcal{S}_{C,A})$ (bzw. CA) angewandt werden. Dabei werden die epistemische Algebra mit Ω_E^A (Ω_E^C) und die Wahrheitsalgebra über dem entsprechenden Universum der möglichen Welten $\mathcal{U}(\mathcal{S}_C)$ mit Ω_T^A (Ω_T^C) bezeichnet.

War eine Evidenz in Abschnitt 5.3.1 noch durch eine Basiswahrscheinlichkeit auf 2^Θ bzw. die mit ihr assoziierte Wahrscheinlichkeitsmasse auf der epistemischen Algebra Ω_E^{ev} gekennzeichnet, so muß nun auch die zusätzliche Information über die Gültigkeit der Constraints $C_{H_i}(A)$ als Teil dieser Evidenz betrachtet werden. Dieser ist gegeben in Form von Wahrscheinlichkeiten

$$P_C(C_{H_i}(A)) = v, \quad P_C(\neg C_{H_i}(A)) = 1 - v$$

für alle $A \subseteq \Theta$, $H_i \in G_\Delta(A)$.

Definition 6.1.11 (revidierte Hypothesenstärke)

Seien $c_{\mathcal{C}(\Theta)} : 2^\Theta \rightarrow [0, 1]$ eine Basiswahrscheinlichkeit auf dem Evidenzenraum, $R = \{s_A \mid A \in \mathcal{C}(\Theta)\}$ eine Regel und $\{P_C(C_{H_i}(A)), P_C(\neg C_{H_i}(A)) \mid H_i \in G_\Delta(A), A \in \mathcal{C}(\Theta)\}$ die Menge aller Bewertungen der Gültigkeit der einzelnen Constraints. Dann heißt die Funktion

$$\begin{aligned} \tilde{r} : 2^\Omega &\rightarrow [0, 1] \\ H &\mapsto \sum_{A \in \mathcal{C}(\Theta)} \sum_{C \in At(\mathcal{S}_{C,A})} \tilde{s}_A^C(H) c_{\mathcal{C}(\Theta)}(A) P_C(C) \end{aligned}$$

die durch die Evidenz $\langle c_{\mathcal{C}(\Theta)}, P_C \rangle$ und Regel R induzierte revidierte Hypothesenstärke.

Die Menge aller Angaben $P_C(\cdot)$ konstituiert nun eine Wahrscheinlichkeitsverteilung P auf Ω_E^A (und damit auch auf Ω_E^C):

$$P_C(C) = P(\mathbf{k}(C)) = P(\mathbf{e}(C)). \quad (6.21)$$

Vor diesem Hintergrund kann die Angabe einer Regel wie R_2 aus Abbildung 6.5 interpretiert werden als die Spezifikation der Werte

$$s_A(H) = P(\mathbf{K}_e H \mid \mathbf{K}_{\mathcal{C}(\Theta)} A, \mathbf{K}(C_{H_1}(A) \wedge \dots \wedge C_{H_n}(A) \wedge C_{\mathcal{P}_0}(A))), \quad H \in G_\Delta(A).$$

Die Angabe des Typs der Regel – und damit die vollständige Beschreibung ihres Modifikationsverhaltens – erlaubt nun die direkte Ableitung *aller* Werte

$$\tilde{s}_A^C(H) = P(\mathbf{K}_e H | \mathbf{K}_{C(\Theta)} A, \mathbf{K}C), \quad H \in G_\Delta(A), C \in At(\mathcal{S}_{C,A}),$$

also die bedingten Wahrscheinlichkeiten aller Hypothesen bei allen 2^n möglichen Kombinationsmöglichkeiten der Constraints $C_{H_i}(A)$ (dabei wird $C_{\mathcal{P}_0}(A)$ als stets erfüllt angenommen). Jede solche Kombination entspricht einem Atom aus $At(\mathcal{S}_{C,A})$ (siehe Anmerkung zu Definition 6.1.10).

Satz 6.1.2 *Die Hypothesenstärke*

$$\tilde{r}(H) = \sum_{A \in \mathcal{C}(\Theta)} \sum_{C \in At(\mathcal{S}_{C,A})} \tilde{s}_A^C(H) c_{C(\Theta)}(A) P_C(C)$$

nach Definition 6.1.11 ist eine Wahrscheinlichkeitsfunktion auf der epistemischen Produktalgebra $\hat{\Omega}_E$ von Ω_E^{ev} , Ω_E^{hyp} und Ω_E^C , und induziert daher eine eindeutig bestimmte Wahrscheinlichkeitsfunktion auf Ω_E^{hyp} .

Beweis:

$$\begin{aligned} \tilde{r}(H) &= \sum_{A \in \mathcal{C}(\Theta)} \sum_{C \in At(\mathcal{S}_{C,A})} \tilde{s}_A^C(H) c_{C(\Theta)}(A) P_C(C) \\ &= \sum_{A \in \mathcal{C}(\Theta)} \sum_{C \in At(\mathcal{S}_{C,A})} P(\mathbf{K}_e H | \mathbf{K}_{C(\Theta)} A, \mathbf{K}C) P(\mathbf{K}_{C(\Theta)} A) P(\mathbf{K}C) \end{aligned}$$

Der Beweis ergibt sich wie für Satz 6.1.1 durch Anwendung der Regel der totalen Wahrscheinlichkeit, wobei ausgenutzt wird, daß sowohl die Erfüllungsmengen der $\mathbf{K}_{C(\Theta)} A$, als auch der $\mathbf{K}C$ das Produktuniversum partitionieren (zum zweiten Punkt siehe (6.21)). \square

Die dieser Berechnung zugrundeliegenden bedingten Unabhängigkeitsannahmen

$$P(\mathbf{K}_{C(\Theta)} A | \mathbf{K}C, \mathcal{E}) = P(\mathbf{K}_{C(\Theta)} A | \mathcal{E}), \quad P(\mathbf{K}C | \mathbf{K}_{C(\Theta)} A, \mathcal{E}) = P(\mathbf{K}C | \mathcal{E}) \quad (6.22)$$

sind gültig, da die Evidenz \mathcal{E} neben der beobachteten Aktion auch das vollständige Wissen zur Beurteilung der Gültigkeit der einzelnen Constraints C beinhaltet. Daher hat – bei gegebenem \mathcal{E} – das Wissen um die Aktion keinerlei Einfluß auf das Wissen bzgl. der Constraints und umgekehrt.

Beispiel 6.1.4 Abbildung 6.6 zeigt eine Beobachtungsregel und drei ihrer möglichen Modifikationen (alle anderen werden für dieses konkrete Beispiel nicht benötigt). Die zugehörigen Listen der Constraintvariablen C_i zeigen deren jeweiligen Status an. Konkret sei eine Evidenz gegeben mit

$$\begin{aligned} P(\mathbf{K}C_1) &= 0.4 & P(\mathbf{K}C_2) &= 0.8 & P(\mathbf{K}C_{\mathcal{P}_0}) &= 1 \\ P(\neg \mathbf{K}C_1) &= 0.6 & P(\neg \mathbf{K}C_2) &= 0.2 & P(\mathbf{K}_{C(\Theta)} A) &= 1 \end{aligned}$$




Abbildung 6.6: Eine Beobachtungsregel mit allen auftretenden Modifikationen.

Der Einfachheit halber wird angenommen, daß die einzelnen $C_i = C_{H_i}(A)$ voneinander unabhängig sind, daß also gilt:

$$P(C_1 \wedge C_2 \wedge C_{\mathcal{P}_0}) = P(C_1) \cdot P(C_2) \cdot P(C_{\mathcal{P}_0}).$$

Um nun die resultierende Hypothesenstärke z.B. für H_1 zu berechnen, sind folgende Schritte notwendig:

$$\underline{\underline{\tilde{r}(H_1)}}$$

$$\begin{aligned} &= P(\mathbf{K}_e H_1 | \mathbf{K}_{C(\Theta)} A, \mathbf{K} C_1 \wedge C_2 \wedge C_{\mathcal{P}_0}) P(\mathbf{K}_{C(\Theta)} A) P(\mathbf{K} C_1) P(\mathbf{K} C_2) P(\mathbf{K} C_{\mathcal{P}_0}) \\ &\quad + P(\mathbf{K}_e H_1 | \mathbf{K}_{C(\Theta)} A, \mathbf{K} \neg C_1 \wedge C_2 \wedge C_{\mathcal{P}_0}) P(\mathbf{K}_{C(\Theta)} A) P(\neg \mathbf{K} C_1) P(\mathbf{K} C_2) P(\mathbf{K} C_{\mathcal{P}_0}) \\ &\quad + P(\mathbf{K}_e H_1 | \mathbf{K}_{C(\Theta)} A, \mathbf{K} C_1 \wedge \neg C_2 \wedge C_{\mathcal{P}_0}) P(\mathbf{K}_{C(\Theta)} A) P(\mathbf{K} C_1) P(\neg \mathbf{K} C_2) P(\mathbf{K} C_{\mathcal{P}_0}) \\ &\quad + P(\mathbf{K}_e H_1 | \mathbf{K}_{C(\Theta)} A, \mathbf{K} \neg C_1 \wedge \neg C_2 \wedge C_{\mathcal{P}_0}) P(\mathbf{K}_{C(\Theta)} A) P(\neg \mathbf{K} C_1) P(\neg \mathbf{K} C_2) P(\mathbf{K} C_{\mathcal{P}_0}) \\ &= 0.2 \cdot 1 \cdot 0.4 \cdot 0.8 \cdot 1 \\ &\quad + 0 \end{aligned}$$

$$\begin{aligned}
& + 0.2 \cdot 1 \cdot 0.4 \cdot 0.2 \cdot 1 \\
& + 0 \\
& = \underline{0.08}
\end{aligned}$$

Für die anderen Hypothesen ergeben sich entsprechend die Werte

$$\tilde{r}(H_2) = 0.24, \quad \tilde{r}(\mathcal{P}_0) = 0.68.$$

Anmerkung: In vielen Anwendungen wie etwa der Planerkennung in intelligenten Hilfesystemen für die Anwender von Software ist es möglich, die Gültigkeit von Constraints $C_H(A)$ eindeutig zu entscheiden, d.h. $P(\mathbf{K}C_H(A)) \in \{0, 1\}$. Dies vereinfacht die Berechnung der revidierten Hypothesenstärke \tilde{r} erheblich, da nun nur noch *eine* Modifikation aller Beobachtungsregeln auftritt, so daß zur Berechnung eines Wertes von \tilde{r} lediglich $|\mathcal{C}(\Theta)|$ Summanden berechnet werden müssen, im Gegensatz zu $|\mathcal{C}(\Theta)| \cdot \sum_{A \in \mathcal{C}(\Theta)} 2^{|G_\Delta(A)|}$ Summanden im allgemeinen, in Definition 6.1.11 beschriebenen Vorgehen. Hier ist

$$\tilde{r}(H) = \sum_{A \in \mathcal{C}(\Theta)} \tilde{s}_A^{C_0} c(A), \quad (6.23)$$

wobei $C_0 \in At(\mathcal{S}_{C,A})$ das eindeutig bestimmte Atom mit $P(\mathbf{K}C_0) = 1$ ist.

Beispiel 6.1.5 Sei in obigem Beispiel die Evidenz gegeben mit

$$\begin{aligned}
P(\mathbf{K}C_1) &= 0 & P(\mathbf{K}C_2) &= 1 & P(\mathbf{K}C_{\mathcal{P}_0}) &= 1 \\
P(\neg \mathbf{K}C_1) &= 1 & P(\neg \mathbf{K}C_2) &= 0 & P(\mathbf{K}_{\mathcal{C}(\Theta)}A) &= 1
\end{aligned}$$

Das ausgezeichnete Atom C_0 ist in diesem Fall $\neg C_1 \wedge C_2 \wedge C_{\mathcal{P}_0}$. Dann ergibt sich als revidierte Hypothesenstärke

$$\begin{aligned}
\tilde{r}(H_1) &= P(\mathbf{K}_e H_1 | \mathbf{K}_{\mathcal{C}(\Theta)} A, \mathbf{K}C_0) P(\mathbf{K}_{\mathcal{C}(\Theta)} A) P(\neg \mathbf{K}C_1) P(\mathbf{K}C_2) P(\mathbf{K}C_{\mathcal{P}_0}) \\
&= 0.0
\end{aligned}$$

$$\begin{aligned}
\tilde{r}(H_2) &= P(\mathbf{K}_e H_2 | \mathbf{K}_{\mathcal{C}(\Theta)} A, \mathbf{K}C_0) P(\mathbf{K}_{\mathcal{C}(\Theta)} A) P(\neg \mathbf{K}C_1) P(\mathbf{K}C_2) P(\mathbf{K}C_{\mathcal{P}_0}) \\
&= 0.3
\end{aligned}$$

$$\begin{aligned}
\tilde{r}(\mathcal{P}_0) &= P(\mathbf{K}_e \mathcal{P}_0 | \mathbf{K}_{\mathcal{C}(\Theta)} A, \mathbf{K}C_0) P(\mathbf{K}_{\mathcal{C}(\Theta)} A) P(\neg \mathbf{K}C_1) P(\mathbf{K}C_2) P(\mathbf{K}C_{\mathcal{P}_0}) \\
&= 0.7
\end{aligned}$$

Die gemäß Definition 6.1.11 gegebene revidierte Hypothesenstärke \tilde{r} repräsentiert den aufgrund der aktuellen Beobachtung den einzelnen Hypothesen zugeordneten Vertrauensgrad. Um den Einfluß sowohl der initialen Hypothesenbewertung m_0 als auch der vorhergehenden Beobachtungen auf die Bewertung der Hypothesen mit einzubeziehen, ist es notwendig, diese miteinander zu verknüpfen.

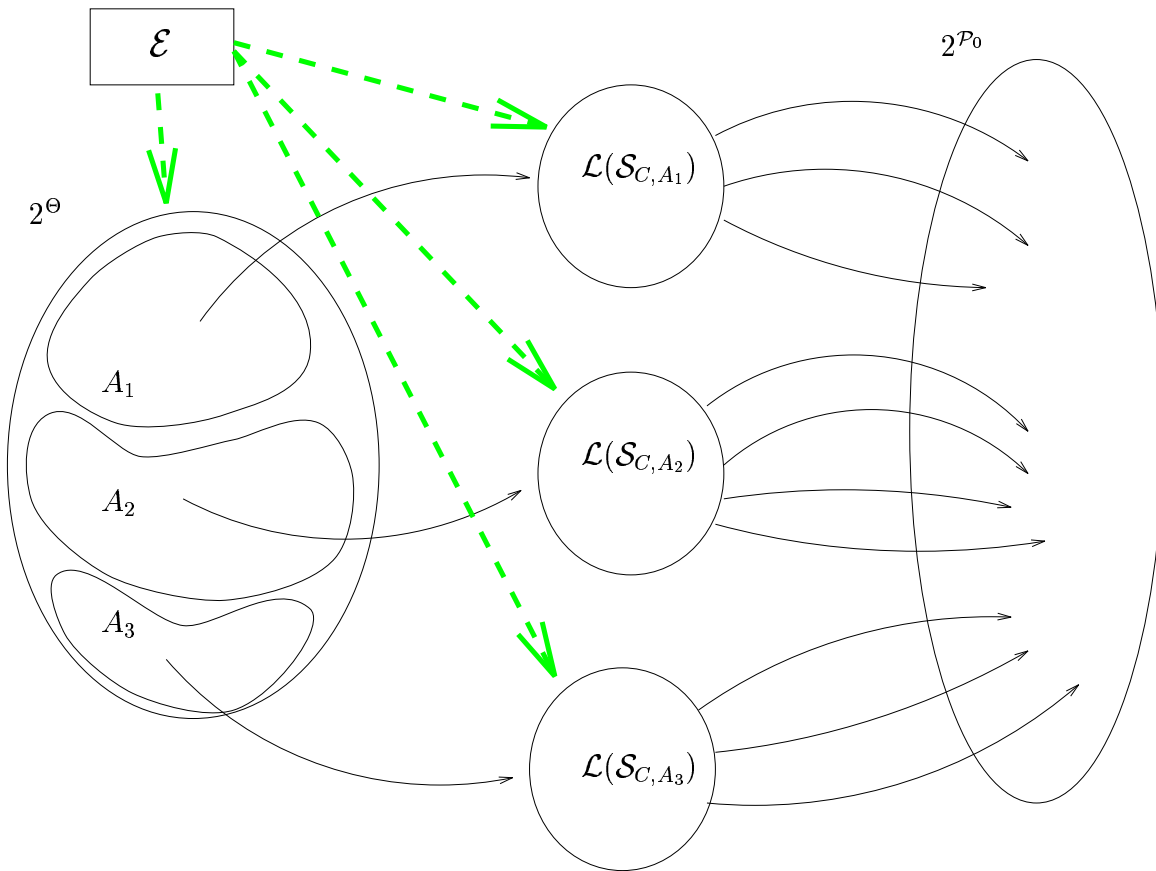


Abbildung 6.7: Der durch eine Evidenz ausgelöste Informationsfluß.

Definition 6.1.12 (aktualisierte Hypothesenbewertung)

Seien $m_i : 2^{\mathcal{P}_0} \rightarrow [0, 1]$ die aktuelle Hypothesenbewertung nach dem i -ten Beobachtungsschritt, $i \geq 0$, \tilde{r}_{i+1} die aus der $i + 1$ -ten Beobachtung resultierende revidierte Hypothesenstärke. Dann heißt

$$\begin{aligned}
 m_{i+1} : 2^{\mathcal{P}_0} &\rightarrow [0, 1] \\
 X &\mapsto (m_i \oplus \tilde{r}_{i+1})(X)
 \end{aligned}$$

die *aktualisierte Hypothesenbewertung nach der $i + 1$ -ten Beobachtung*.

Anmerkung: Die Einführung einer Δ -Partitionierung $\mathcal{C}(\Theta)$ führt dazu, daß es für bestimmte $A \subseteq \Theta$ keine Beobachtungsregeln gibt. Die zugehörigen Constraints $C_H(A)$ für alle A enthaltenden Planhypothesen H dürfen jedoch nicht vernachlässigt werden. Eine Zusammenfassung von Beobachtungsregeln ist daher nur zulässig, wenn

die Constraintmengen $C_H(A)$ aller zusammengefaßten Evidenzen übereinstimmen, so daß dadurch keine Information verlorengeht. Als Nebeneffekt ergibt sich, daß diese Constraints nur einmal überprüft werden müssen.

Abbildung 6.7 veranschaulicht nochmals den durch eine Evidenz \mathcal{E} mit Auswirkungen auf den Evidenzenraum 2^Θ und die Constraintalgebren $\mathcal{L}(\mathcal{S}_{C,A_i})$ ausgelösten Informationsfluß, der in der partiellen Anwendung der Beobachtungsregeln bzw. der Anwendung ihrer entsprechenden Modifikationen besteht und schließlich zu einer Bewertung des Hypothesenraumes $2^{\mathcal{P}_0}$ führt.

6.2 Der Planerkennungsprozeß

Während die ersten Abschnitte dieses Kapitels die Repräsentation des während der Planerkennung und der Bewertung der Hypothesen verwendeten Wissens beschrieben, ist der Inhalt dieses Abschnitts dessen Verwendung innerhalb eines Planerkennungsprozesses. Dabei geht es im ersten Teil um die konkrete *Verarbeitung einer Beobachtung* im Rahmen der Planerkennung in unterschiedlichen Szenarien und die dabei zu berücksichtigenden Besonderheiten. Der zweite Teil ist der *Interpretation* der berechneten numerischen Hypothesenbewertungen gewidmet. Dabei geht es sowohl um die Vorstellung von Methoden zur Auswahl von Planhypothesen auf der Basis gewisser Qualitätskriterien als auch um die Rechtfertigung solcher Entscheidungen gegenüber dem Benutzer eines solchen Systems.

6.2.1 Verarbeitung einer Beobachtung

Nachdem das prinzipielle Vorgehen in 6.2.1.1 erläutert wird, werden vier unterschiedlichen Szenarien vorgestellt, an deren Beispiel die Bewertung von Planhypothesen veranschaulicht werden soll. Diese Szenarien unterscheiden sich durch die Präzision der jeweils möglichen Beobachtungen sowie die Anzahl der involvierten Beobachter. Sie basieren auf einer konzeptuellen Kopplung mit dem in [Allen, 1991, Kapitel 2] von Kautz vorgestellten Planerkenner.

In einer ersten Version werden *eindeutige Beobachtungen* betrachtet, bei denen die Evidenz spezifisch genug ist, eine Basisaktion zu identifizieren (siehe Abschnitt 6.2.1.2). Die zweite Stufe behandelt *disjunktive Beobachtungen*, bei denen lediglich eine *Menge* von Basisaktionen angegeben werden kann, die die aktuelle Aktion des Agenten beinhaltet (Abschnitt 6.2.1.3). Ein noch allgemeinerer Fall einer Beobachtung wird repräsentiert durch eine *Basiswahrscheinlichkeit über dem Evidenzenraum*, die den Vertrauensgrad in das Auftreten der verschiedenen möglichen Aktionen angibt (Abschnitt 6.2.1.4). Das letzte Szenario schließlich behandelt den Fall mehrerer Beobachter. Dabei wird zunächst eine Variante untersucht, in der alle Beobachtungen als vollkommen zuverlässig betrachtet werden (Abschnitt 6.2.1.5), bevor eine Methode zur Behandlung teilweise unzuverlässiger Beobachtungen vorgestellt wird (Abschnitt 6.2.1.5.1). Bei allen Beispielen wird davon ausgegangen, daß die Gültigkeit der

Constraints zwischen Aktionen und Plänen eindeutig entscheidbar ist. Die Behandlung des allgemeinsten Falles von Constraints findet sich u.a. in Abschnitt 6.1.3.3.2.

Der erste Fall mit präzisen Beobachtungen wird im Rahmen der Beobachtung eines Softwareanwenders nochmals ausführlich im Zusammenhang mit der Verwendung der vorgestellten Konzepte in den Projekten PHI und RAP in Kapitel 7 behandelt.

6.2.1.1 Das prinzipielle Vorgehen

Das Vorgehen bei der Verarbeitung einer Evidenz gliedert sich grundsätzlich in fünf Schritte:

1. Regelauswahl

Auf der Basis der aktuellen Beobachtung werden die anwendbaren Beobachtungsregeln ausgewählt, also gerade diejenigen, deren Prämisse erfüllt oder zumindest Fokalelement einer die Evidenz repräsentierenden Basiswahrscheinlichkeit ist.

2. Modifikation

Diese Regeln werden unter Verwendung der vom Planerkenner gelieferten Information über die Gültigkeit der Constraints zwischen Aktionen und Planhypothesen gemäß Definition 6.1.8 modifiziert.

3. Regelanwendung

Die Anwendung dieser modifizierten Regeln entspricht der Berechnung der revidierten Hypothesenstärke \tilde{r} gemäß Definition 6.1.11.

4. Aktualisierung der Hypothesenbewertung

Die momentane Hypothesenbewertung, die entweder die durch das Benutzermodell oder die in Abschnitt 6.3.2.1 beschriebenen Heuristiken initialisiert wurde oder aber das Ergebnis vorheriger Planerkennungsschritte ist, wird mit \tilde{r} verknüpft, so daß diese *alle* bisherigen Beobachtungen widerspiegelt. Das Ergebnis ist die aktualisierte Hypothesenbewertung gemäß Definition 6.1.12.

5. Überprüfung der Auswahlkriterien

Erfüllt eine der Planhypothesen ein bestimmtes Qualitätskriterium, so wird diese als Ergebnis des aktuellen Planerkennungszyklus angeboten. Andernfalls wird die nächste Beobachtung verarbeitet. Zur Problematik der Definition solcher Kriterien sei hier auf Abschnitt 6.2.2.1 verwiesen.

Diesem Vorgehen liegen im wesentlichen zwei Unabhängigkeitsannahmen zugrunde. Die erste betrifft die Unabhängigkeit der Beobachtungen in Szenarien mit mehreren Beobachtern. Unabhängigkeit ist in dem Sinne zu verstehen, daß die von den verschiedenen Beobachtern erzielten Hypothesenbewertungen mit Hilfe von Dempsters Regel miteinander kombinierbar sein müssen, um zu einem Gesamturteil zu gelangen (vergleiche Definition 6.2.1). Die zweite Annahme betrifft die Ergebnisse

aufeinanderfolgender Planerkennungszyklen und schlägt sich in erster Linie bei der Aktualisierung der initialen Hypothesenbewertung (siehe Abschnitt 6.3.2.1) nieder. Es wird davon ausgegangen, daß ein Agent denselben Plan beliebig oft hintereinander ausführen kann. Eine solche Annahme ist für den Fall des hier betrachteten Küchenszenarios zwar problematisch – ein Agent wird wahrscheinlich nicht an zwei aufeinanderfolgenden Tagen dasselbe Gericht kochen – im realistischeren Fall von Planerkennung in Hilfesystemen jedoch durchaus vertretbar. Für Anwendungen, die dieser Annahme widersprechen, müßte eine Übergangsfunktion von der finalen Hypothesenbewertung eines Zyklus zur initialen Bewertung des nächsten definiert werden, die solche Überlegungen miteinbezieht.

6.2.1.2 Präzise Beobachtungen

Sei wieder die Planhierarchie \mathcal{H} aus Abbildung 6.1 gegeben. Gemäß den Ausführungen in Abschnitt 6.1.3 ergeben sich bei ihrer Repräsentation in der Dempster-Shafer folgende Werte für die Menge der Basispläne \mathcal{P}_0 und der Basisaktionen Θ

$$\mathcal{P}_0 = \{ \text{MakeSpaghettiCarbonara, MakeFettuciniAlfredo,} \\ \text{MakeFettuciniMarinara, MakeChickenMarinara,} \\ \text{MakeChickenPrimavera, StackBlocks } \}$$

$$\Theta = \{ \text{GoToKitchen, Boil,} \\ \text{MakeSpaghetti, MakeFettucini,} \\ \text{MakeSauceAlfredo, MakeSauceCarbonara,} \\ \text{MakeMarinara } \},$$

die Darstellung der abstrakten Pläne als Teilmengen von \mathcal{P}_0 gemäß Definition 6.1.2 und der abstrakten Aktionen als Teilmengen von Θ

$$M(\text{MakePastaDish}) = \{ \text{MakeSpaghettiCarbonara,} \\ \text{MakeFettuciniAlfredo,} \\ \text{MakeFettuciniMarinara } \}$$

$$M(\text{MakeMeatDish}) = \{ \text{MakeChickenMarinara, MakeChickenPrimavera } \}$$

$$M(\text{PrepareMeal}) = M(\text{MakePastaDish}) \cup M(\text{MakeMeatDish})$$

$$M(\text{TopLevelAct}) = \mathcal{P}_0$$

$$M(\text{MakeNoodles}) = \{ \text{MakeSpaghetti, MakeFettucini } \}$$

$$M(\text{MakeSauce}) = \{ \text{MakeSauceAlfredo, MakeSauceCarbonara, MakeMarinara } \}$$

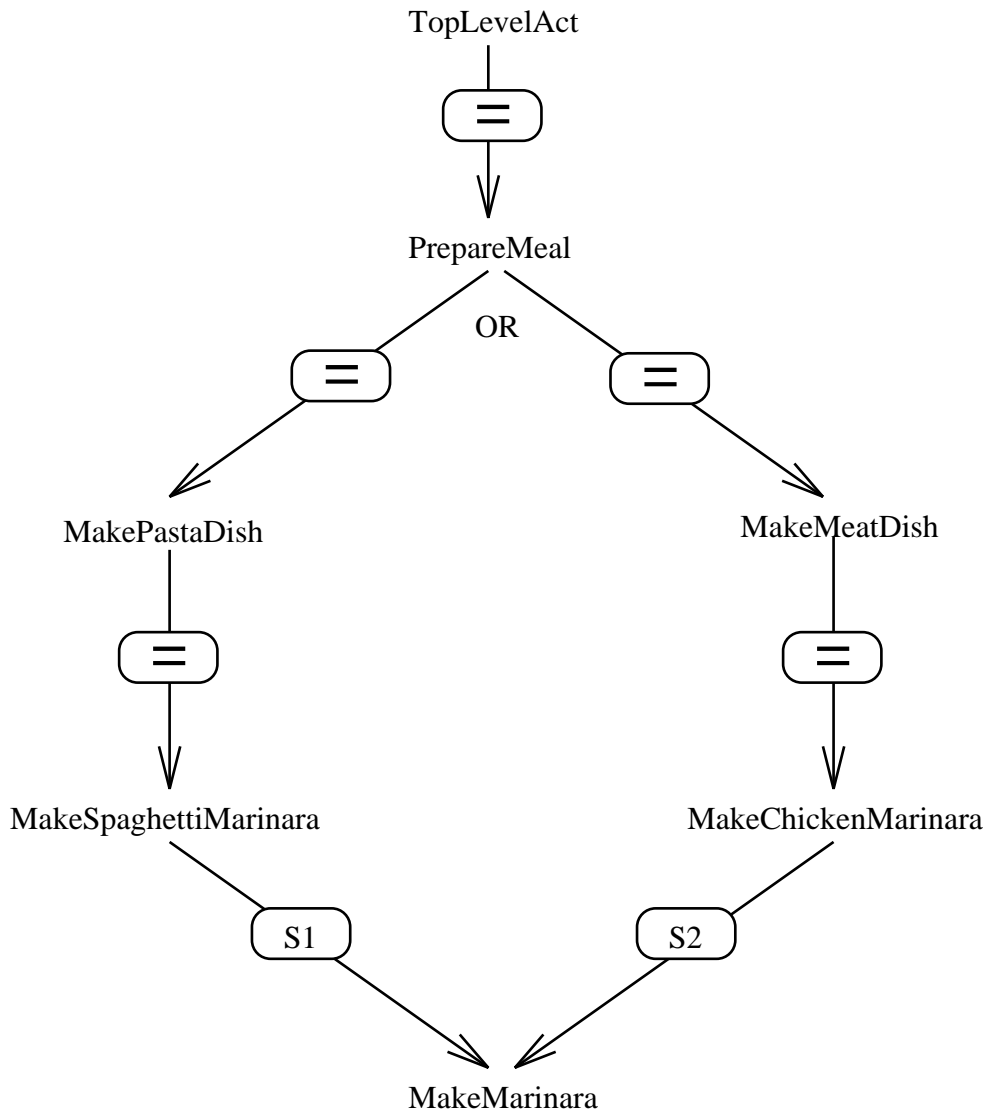
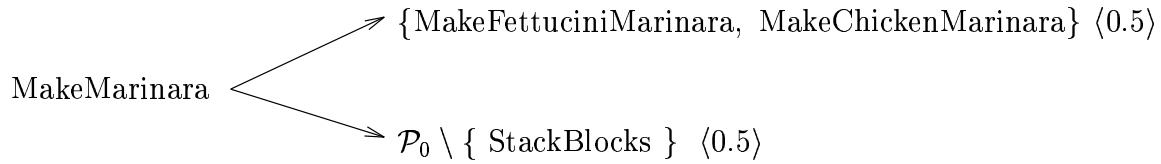


Abbildung 6.8: Der Erklärungsgraph nach der Beobachtung MakeMarinara.

Das quantitative Benutzermodell enthalte ferner eine initiale Hypothesenbewertung m_0 mit

$$m_0(X) = \begin{cases} 0.8, & X = M(\text{MakePastaDish}) \\ 0.2, & X = M(\text{TopLevelAct}) \\ 0.0, & \text{sonst} \end{cases} \quad (6.24)$$

die eine gewisse Tendenz des Agenten zu Nudelgerichten deutlich macht, jedoch sehr unspezifisch ist. Ferner sei u.a. folgende Beobachtungsregel gegeben, die wie in Abschnitt 6.1.3.2 beschrieben mit einem Wert von 0.5 für die Konstante c_0 initialisiert wurde:



Die dem in [Kautz, 1991] beschriebenen Planerkennungsverfahren zugrundeliegende Theorie beruht darauf, gewisse Schlüsse zu ziehen, die innerhalb der minimalen Modelle der eine gegebene Planhierarchie repräsentierenden logischen Theorie gültig sind. Diese Modelle werden durch die wiederholte Anwendung der Circumscription auf diese Theorie ermittelt und beschreiben im wesentlichen Abschlußeigenschaften wie die Vollständigkeit der Abstraktions- und Dekompositionshierarchie (siehe dazu auch [Kautz und Allen, 1986] und Abschnitt 6.1.3.1). Ziel dieser Schlußfolgerungen ist die Ableitung der Aussage, daß die beobachtete Aktion Teil einer Instanz der Aktion TopLevelAct ist.

Die praktische Umsetzung erfolgt durch den Aufbau sogenannter *Erklärungsgraphen*, die die wesentlichen Aspekte der Abstraktion und Dekompositionsrelation im Zusammenhang mit einer aktuellen Beobachtung darstellen. Ziel ist es dabei, innerhalb eines solchen Graphen einen Pfad vom Knoten TopLevelAct zu dieser Aktion zu finden. Abbildung 6.8 zeigt einen solchen Graphen nach der Beobachtung einer Instanz der Basisaktion MakeMarinara.

Dabei bedeutet ein Label = an einer Kante, daß die mit dem Vaterknoten assoziierte Ereignisinstanz mit derjenigen des Sohnknotens identisch ist. Die Markierung OR steht dabei für mehrere Alternativen einer solchen Gleichsetzung. Die anderen Markierungen denotieren die Teilschrittbeziehung, etwa $S(1, plan) = \text{MakeMarinara}$ in der Dekomposition von MakeSpaghettiMarinara. Implizit sind mit solchen Kanten auch die entsprechenden Constraints zwischen Plan und Aktion assoziiert, wie dies etwa in (6.1) dargestellt ist. Das Vorhandensein einer Kante zwischen zwei Knoten in einem Erklärungsgraphen deutet darauf hin, daß alle Constraints zwischen Vater- und Sohnknoten erfüllt sind.

Die Überprüfung der Constraints zur Revidierung der Regelgewichte gemäß dem in Abschnitt 6.1.3.3.1 beschriebenen Verfahren ist somit sehr einfach. Seien $A \subseteq \Theta$ eine Aktion(smeng)e mit assoziierter Hypothesenmenge (siehe Anmerkungen zu Definition 5.2.1)

$$G_{\Delta}(A) = \{H_1, \dots, H_n\}.$$

$EG(A) = (V, E)$ sei ein Erklärungsgraph für die Beobachtung A mit einer Menge V von Knoten und einer Menge E gerichteter Kanten. Dann gilt

$$\begin{aligned} C_{H_i}(A) & \text{ genau dann, wenn } \begin{cases} H_i \in V \text{ und} \\ \text{es gibt einen Pfad von } H_i \text{ nach } A \text{ in } EG(A) \end{cases} \\ \neg C_{H_i}(A) & \text{ genau dann, wenn } \begin{cases} H_i \notin V \text{ oder} \\ \text{es gibt keinen Pfad von } H_i \text{ nach } A \text{ in } EG(A) \end{cases} \end{aligned}$$

Hypothese	m_1	Bel_{m_1}	Pl_{m_1}
MakeSpaghettiCarbonara	0.0	0.0	0.5
MakeFettuciniAlfredo	0.0	0.0	0.5
MakeFettuciniMarinara	0.4	0.4	1.0
MakeChickenMarinara	0.0	0.0	0.2
MakeChickenPrimavera	0.0	0.0	0.1
StackBlocks	0.0	0.0	0.0
MakePastaDish	0.4	0.8	1.0
MakeMeatDish	0.0	0.0	0.2
PrepareMeal	0.1	1.0	1.0
TopLevelAct	0.0	1.0	1.0

Tabelle 6.2: Die durch m_1 induzierten Vertrauensintervalle für die Pläne der Abstraktionshierarchie.

Die Bedingung, daß es einen Pfad von dem die Hypothese repräsentierenden Knoten zum Beobachtungsknoten gibt, ist dann von Interesse, wenn der Erklärungsgraph etwa im Falle unsicherer Beobachtungen mehrere solcher Knoten enthält.

Alle in Knoten von $EG(A)$ repräsentierten Pläne können gemäß Kautz' Theorie aus der Beobachtung MakeMarinara mit den entsprechenden Parametern abgeleitet werden. Insbesondere ist die spezifischste Aussage bzgl. des verfolgten Planes die Disjunktion des Auftretens von MakeFettuciniMarinara und MakeChickenMarinara.

Berücksichtigt man nun die o.a. initiale Hypothesenbewertung m_0 sowie die gewichtete Beobachtungsregel für MakeMarinara, so ergibt sich für die aktuelle Situation mit $c(\{\text{MakeMarinara}\}) = 1$ eine revidierte Hypothesenstärke \tilde{r} mit

$$\tilde{r}(X) = \begin{cases} 0.5, & X = \{ \text{MakeFettuciniMarinara}, \text{MakeChickenMarinara} \} \\ 0.5, & X = \mathcal{P}_0 \setminus \{ \text{StackBlocks} \} \\ 0.0, & \text{sonst} \end{cases}$$

die exakt den Gewichten der angewandten Regel entspricht. Die Kombination von m_0 mit \tilde{r} ergibt dann eine aktuelle Hypothesenbewertung $m_1 = m_0 \oplus \tilde{r}$ mit

$$m_1(X) = \begin{cases} 0.4, & X = \{ \text{MakeFettuciniMarinara} \} \\ 0.4, & X = \text{MakePastaDish} \\ 0.1, & X = \{ \text{MakeFettuciniMarinara}, \text{MakeChickenMarinara} \} \\ 0.1, & X = \mathcal{P}_0 \setminus \{ \text{StackBlocks} \} \\ 0.0, & \text{sonst} \end{cases}$$

Betrachtet man die durch m_1 induzierten Vertrauensintervalle der entsprechenden Hypothesen, so erhält man $[0.4, 1.0]$ für MakeFettuciniMarinara und lediglich $[0.0, 0.2]$ für MakeChickenMarinara. Zu beachten ist, daß StackBlocks zu diesem Zeitpunkt bereits als Hypothese nicht mehr in Frage kommt, da das entsprechende Vertrauensintervall auf $[0.0, 0.0]$ zusammengeschrumpft ist. Insgesamt ergeben sich die in Tabelle 6.2 angegebenen Werte für die Elemente der Abstraktionshierarchie. Der Übersichtlichkeit wegen wurden Hypothesenmengen wie $\{ \text{MakeFettuciniMarinara, MakeChickenMarinara} \}$, die keinem abstrakten Plan entsprechen, weggelassen. Deren Vertrauensintervalle können direkt aus den Werten für m_1 abgelesen werden.

Gemäß den in Abschnitt 6.2.1.1 aufgelisteten Schritten bei der Verarbeitung von Evidenzen läßt sich das Vorgehen bei präzisen Beobachtungen folgendermaßen beschreiben. Seien dazu $a_0 \in \Theta$ die eindeutig identifizierte Aktion des Agenten, \mathcal{C} die aktuelle Δ -Partitionierung von Θ (vergleiche Abbildung 6.1):

$$\begin{aligned} \mathcal{C} &= \{ \{ \text{GoToKitchen} \} && \text{(a)} \\ &\{ \text{Boil} \} && \text{(b)} \\ &\{ \text{MakeSpaghetti} \} && \text{(c)} \\ &\{ \text{MakeFettucini} \} && \text{(d)} \\ &\{ \text{MakeSauceCarbonara} \} && \text{(e)} \\ &\{ \text{MakeSauceAlfredo} \} && \text{(f)} \\ &\{ \text{MakeMarinara} \} && \text{(g)} \\ M(\text{MakeNoodles}) &= \{ (c), (d) \} \\ M(\text{MakeSauce}) &= \{ (e), (f), (g) \} \\ \Theta &= \{ (a), (b), (c), (d), (e), (f), (g) \} \end{aligned}$$

1. Genau eine Regel ist anwendbar. Ihre Prämisse sei $\mathbf{K}_c A_0$ (es gilt also $a_0 \in A_0$).
2. Die Menge der gültigen Constraints, repräsentiert durch das Atom C_0 (vergleiche Anmerkungen zu Definition 6.1.10)– und damit die notwendige Modifikation dieser Regel – kann aufgrund der Information des Planerkenners berechnet werden. Im konkreten Fall geschieht dies durch Wegesuche in einem Erklärungsgraphen.
3. Die Berechnung der revidierten Hypothesenbewertung vereinfacht sich zu

$$\tilde{r}(H) = \tilde{s}_{A_0}^{C_0}(H),$$

da nur *eine* Modifikation der Regelgewichte zu betrachten ist und die Basiswahrscheinlichkeit c auf Θ – und damit auch die induzierte Basiswahrscheinlichkeit c_c – nur *ein* Fokalelement (nämlich $\{a_0\}$ bzw. A_0) hat.

4. Die Berechnung der aktuellen Hypothesenbewertung geschieht wie üblich durch Anwendung von Dempsters Regel.
5. Für die Diskussion von Auswahlkriterien sei auf Abschnitt 6.2.2.1 verwiesen.

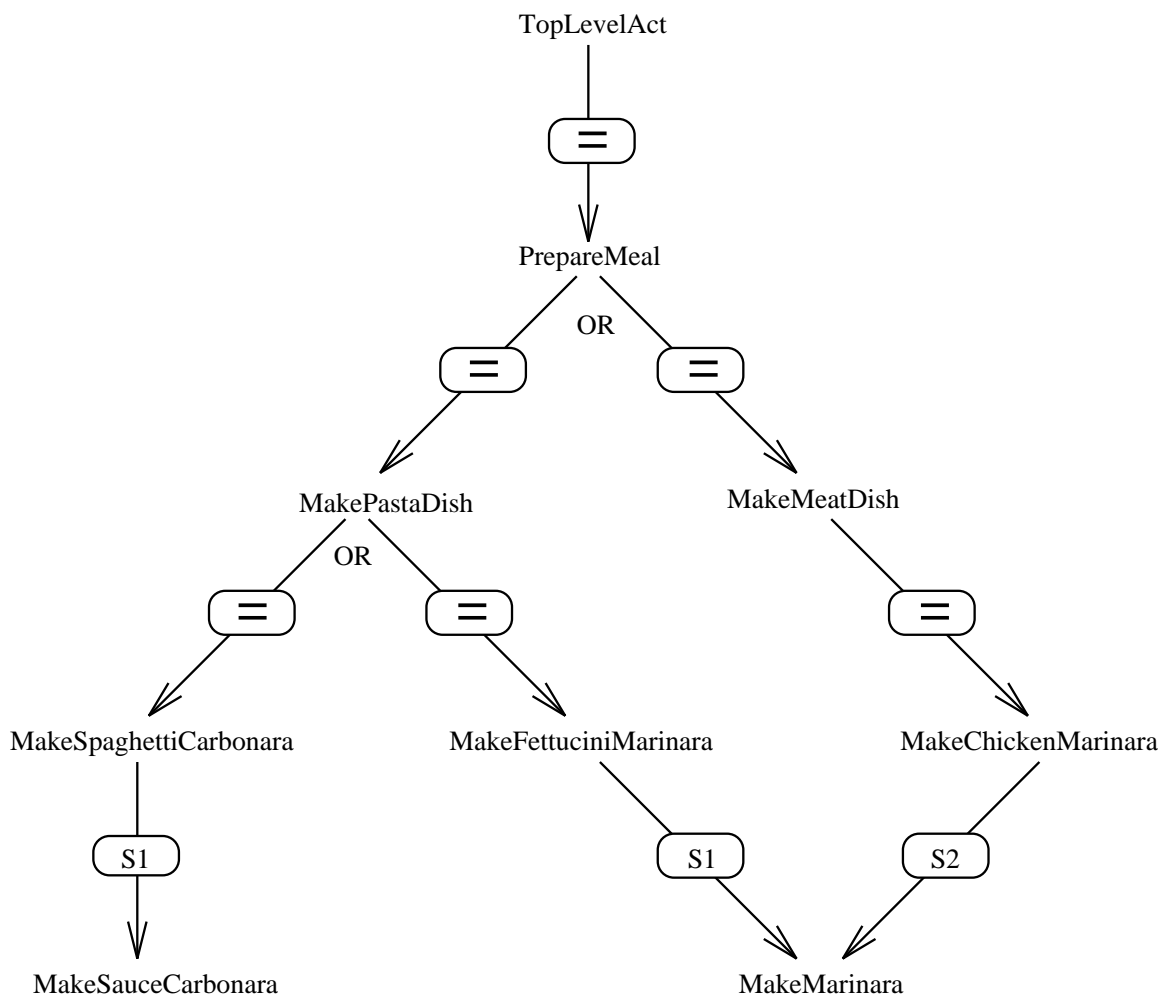



Abbildung 6.9: Der Erklärungsgraph der disjunktiven Beobachtung MakeSauceCarbonara \vee MakeMarinara.

6.2.1.3 Disjunktive Beobachtungen


Gegeben sei weiterhin das bereits im vorigen Abschnitt verwendete Szenario. Die aktuelle Beobachtung sei diesmal MakeSauceCarbonara \vee MakeMarinara. Abbildung 6.9 zeigt den resultierenden Erklärungsgraphen. Ferner sei u.a. folgende Beobachtungsregel gegeben, die wiederum mit einem Wert von $c_0 = 0.5$ (wie in Abschnitt 6.1.3.2 beschrieben) initialisiert wurde:



Hypothese	m'_1	$Bel_{m'_1}$	$Pl_{m'_1}$
MakeSpaghettiCarbonara	0.0	0.0	1.0
MakeFettuciniAlfredo	0.0	0.0	0.5
MakeFettuciniMarinara	0.0	0.0	1.0
MakeChickenMarinara	0.0	0.0	0.2
MakeChickenPrimavera	0.0	0.0	0.1
StackBlocks	0.0	0.0	0.0
MakePastaDish	0.4	0.8	1.0
MakeMeatDish	0.0	0.0	0.2
PrepareMeal	0.1	1.0	1.0
TopLevelAct	0.0	1.0	1.0

Tabelle 6.3: Die durch m'_1 induzierten Vertrauensintervalle für die Pläne aus \mathcal{H} .

Gemäß der Definition der Δ -Partitionierung \mathcal{C} von Θ im vorigen Abschnitt ist diese die einzige anwendbare Regel. Wie dem Erklärungsgraphen in Abbildung 6.9 leicht zu entnehmen ist, sind die Constraints für MakeFettuciniAlfredo und MakeChickenPrimavera *nicht* erfüllt, was zu folgender modifizierten Beobachtungsregel für MakeSauce führt



Diese Regelgewichte entsprechen somit auch den Werten der revidierten Hypothesenstärke \tilde{r} , deren Kombination mit der initialen Hypothesenbewertung m_0 aus (6.24) folgende aktuelle Hypothesenbewertung m'_1 ergibt:

$$m'_1(X) = \begin{cases} 0.4, & X = \{ \text{MakeSpaghettiCarbonara, MakeFettuciniMarinara} \} \\
 0.4, & X = \text{MakePastaDish} \\
 0.1, & X = \{ \text{MakeSpaghettiCarbonara, MakeFettuciniMarinara,} \\
 & \text{MakeChickenMarinara} \} \\
 0.1, & X = M(\text{PrepareMeal}) \\
 0.0, & \text{sonst} \end{cases}$$

Die daraus resultierenden Vertrauensintervalle für die in der Planhierarchie ent-

haltenen Pläne können Tabelle 6.3 entnommen werden.

Beschreibt man die Verarbeitung einer disjunktiven Beobachtung anhand der fünf Schritte aus Abschnitt 6.2.1.1, so stellt man fest, daß es hierbei keinen prinzipiellen Unterschied gegenüber der Behandlung präziser Beobachtungen gibt. Lediglich das im letzten Abschnitt definierte Kriterium für die Gültigkeit von Constraints muß erweitert werden. Sei dazu $A \subseteq \Theta$ mit $H_i \in G_\Delta(A)$. Dann gilt:

$$C_{H_i}(A) \text{ genau dann, wenn } \begin{cases} H_i \in V \text{ und} \\ \text{es gibt einen Pfad von } H_i \text{ nach } A' \text{ in } EG(A) \\ \text{für ein } A' \subseteq A \end{cases}$$

$$\neg C_{H_i}(A) \text{ sonst}$$

Im obigen Beispiel bedeutet dies etwa, daß die notwendigen Constraints bzgl. MakeSpaghettiCarbonara erfüllt sind, da es einen Pfad von diesem Knoten zu MakeSauceCarbonara im Erklärungsgraphen gibt, das als einelementige Teilmenge der Beobachtung interpretiert wird.

Anmerkungen:

1. Die Tatsache, daß genau eine Beobachtungsregel anwendbar ist, beruht auf der Identifizierung einer disjunktiven Beobachtung $a_1 \vee \dots \vee a_n$ mit der logischen Formel

$$\mathbf{K}_e(a_1 \vee \dots \vee a_n),$$

so daß es in der Δ -Partitionierung von Θ *genau ein* $A_0 \subseteq \Theta$ gibt mit

$$\mathbf{K}_e(a_1 \vee \dots \vee a_n) \Rightarrow \mathbf{K}_c A_0.$$

2. Die Anwendung aller Regeln, deren Prämisse durch eines der a_i erfüllt wird, entspräche demgegenüber der *konjunktiven* Verknüpfung der a_i im Sinne mehrerer voneinander unabhängiger Beobachtungen.

6.2.1.4 Unsichere Beobachtungen

Waren die Beobachtungen im letzten Abschnitt noch durch eine Disjunktion $\mathbf{K}_e(a_1 \vee \dots \vee a_n)$ elementarer Aktionen als spezifischste Aussage gekennzeichnet, wodurch nur eine Beobachtungsregel angewendet werden konnte, so äußert sich die Unsicherheit der hier betrachteten Beobachtungen auf eine andere Art. Der Typ von Evidenzen, der nun untersucht wird, ist charakterisiert durch Formeln der Form

$$\mathbf{K}_e A_1 \vee \dots \vee \mathbf{K}_e A_n$$

mit $A_i \subseteq \Theta$, wobei jedem Disjunkt eine bestimmte Wahrscheinlichkeit in der epistemischen Algebra des Evidenzenraumes zugeordnet ist. D.h. die Basiswahrscheinlichkeit c , die die Evidenz repräsentiert, hat hier i.a. mehrere Fokalelemente.

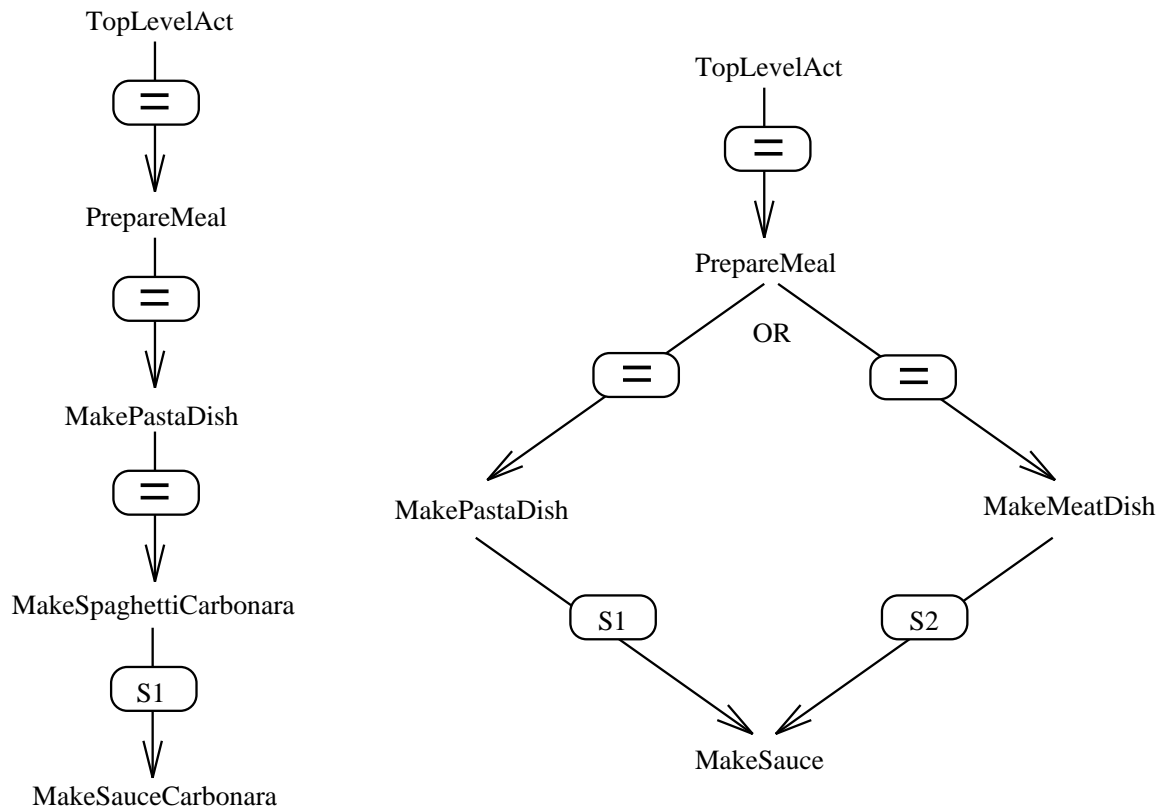


Abbildung 6.10: Die Erklärungsgraphen für die Beobachtungen MakeSauceCarbonara und MakeSauce.

Evidenzen dieser Art sind beispielsweise dann denkbar, wenn die Aktionen des Agenten nicht direkt beobachtet werden können, sondern lediglich deren Effekte in der Welt. In einer ersten Phase muß dann zunächst auf die in Frage kommenden Aktionen geschlossen werden, wodurch sich eine der Hypothesenbewertung \tilde{r} ähnliche Bewertung c der Elemente des Evidenzenraumes ergibt. Die formale Behandlung eines solchen Szenarios findet sich in Abschnitt 6.2.1.6.

Sei also nochmals das Szenario der letzten beiden Abschnitte gegeben. Die aktuelle Evidenz sei charakterisiert durch $c : 2^{\Theta} \rightarrow [0, 1]$ mit


$$c(X) = \begin{cases} 0.2, & X = \{\text{MakeMarinara}\} \\ 0.3, & X = \{\text{MakeSauceCarbonara}\} \\ 0.5, & X = \text{MakeSauce} \\ 0.0, & \text{sonst} \end{cases}$$

Diese Beobachtung wird durch eine Menge von Erklärungsgraphen repräsentiert, von denen jeder jeweils eines der Fokalelemente von c erklärt. Neben dem Graphen aus Abbildung 6.8 ergeben sich somit zusätzlich die Erklärungsgraphen aus Abbildung 6.10. Zusätzlich zu den bereits vorgestellten Beobachtungsregeln für MakeMa-

Hypothese	m_1''	$Bel_{m_1''}$	$Pl_{m_1''}$
MakeSpaghettiCarbonara	0.15	0.15	0.90
MakeFettuciniAlfredo	0.00	0.00	0.75
MakeFettuciniMarinara	0.08	0.08	0.85
MakeChickenMarinara	0.00	0.00	0.17
MakeChickenPrimavera	0.00	0.00	0.15
StackBlocks	0.00	0.00	0.00
MakePastaDish	0.60	0.83	1.0
MakeMeatDish	0.00	0.00	0.17
PrepareMeal	0.15	1.0	1.0
TopLevelAct	0.0	1.0	1.0

Tabelle 6.4: Die durch m_1'' induzierten Vertrauensintervalle für die Pläne aus \mathcal{H} .

Marinara in Abschnitt 6.2.1.2 und für MakeSauce in Abschnitt 6.2.1.3 sei die auf die gleiche Weise initialisierte Regel



gegeben. Als revidierte Hypothesenstärke \tilde{r} ergibt sich

$$\tilde{r}(X) = \begin{cases} 0.10, & X = \{ \text{MakeFettuciniMarinara}, \text{MakeChickenMarinara} \} \\ 0.15, & X = \{ \text{MakeSpaghettiCarbonara} \} \\ 0.75, & X = M(\text{PrepareMeal}) \\ 0.00, & \text{sonst} \end{cases}$$

Als Werte der aktuellen Hypothesenbewertung m_1'' ergeben sich

$$m_1''(X) = \begin{cases} 0.02, & X = \{ \text{MakeFettuciniMarinara}, \text{MakeChickenMarinara} \} \\ 0.08, & X = \{ \text{MakeFettuciniMarinara} \} \\ 0.15, & X = \{ \text{MakeSpaghettiCarbonara} \} \\ 0.15, & X = M(\text{PrepareMeal}) \\ 0.60, & X = M(\text{MakePastaDish}) \end{cases}$$

Die induzierten Vertrauensintervalle für die Elemente der Planhierarchie können der Tabelle 6.4 entnommen werden.

Anmerkungen:

1. Anwendbar sind in einem solchen Szenario alle Regeln mit Prämisse $\mathbf{K}_c A_0$, für die es ein Fokalelement A von c gibt mit $\mathbf{K}_e A \Rightarrow \mathbf{K}_c A_0$.
2. Zur Feststellung der Gültigkeit von Constraints muß in einem solchen Fall ein Pfad von einer Planhypothese zur beobachteten Aktion in *einem* der gegebenen Erklärungsgraphen gefunden werden.

6.2.1.5 Mehrere Beobachter

Bisher wurde stets davon ausgegangen, daß *ein* Beobachter den Agenten bei der Durchführung von Aktionen überwacht. Es ist jedoch auch möglich, die Resultate *mehrerer* voneinander unabhängige Beobachter bei der Bewertung der Hypothesen zu berücksichtigen. In diesem Fall muß aus den Einzelergebnissen dieser Beobachter zunächst eine Bewertung berechnet werden, die den *Gesamteindruck* aller Beobachter widerspiegelt.

Definition 6.2.1 (akkumulierte Hypothesenstärke)

Es seien $n > 1$ verschiedene, voneinander unabhängige Beobachter gegeben. Aufgrund der aktuellen Beobachtung ergebe sich für jeden von ihnen eine revidierte Hypothesenstärke $\tilde{r}_i, i = 1, \dots, n$ auf einem gemeinsamen Hypothesenraum. Dann ist

$$\tilde{r}_{1,\dots,n} = \tilde{r}_1 \oplus \dots \oplus \tilde{r}_n$$

die *akkumulierte Hypothesenstärke* der Beobachter $1, \dots, n$.

6.2.1.5.1 Zuverlässige Beobachtungen

Zunächst wird angenommen, daß die Aussagen aller Beobachter als vollkommen zuverlässig betrachtet werden. Seien konkret die Beobachtungen aus Abschnitt 6.2.1.4 von drei verschiedenen Beobachtern über denselben Evidenzenraum gemacht worden. Diese Evidenzen seien beschrieben durch die Basiswahrscheinlichkeiten c_1, c_2, c_3 mit

$$c_1(X) = \begin{cases} 0.2, & X = \{\text{MakeMarinara}\} \\ 0.8, & X = \text{Action} \\ 0.0, & \text{sonst} \end{cases}$$

$$c_2(X) = \begin{cases} 0.3, & X = \{\text{MakeSauceCarbonara}\} \\ 0.7, & X = \text{Action} \\ 0.0, & \text{sonst} \end{cases}$$

$$c_3(X) = \begin{cases} 0.5, & X = \text{MakeSauce} \\ 0.5, & X = \text{Action} \\ 0.0, & \text{sonst} \end{cases}$$

Dabei ist Action wie in Abschnitt 6.1.1 erläutert die Aktion, die alle anderen abstrahiert. Die ihr zugeordnete Aktionsmenge $M(\text{Action})$ ist somit die Menge aller Aktionen. Da sie in keinem der Pläne der gegebenen Planhierarchie explizit vorkommt, existiert für sie lediglich die in Abschnitt 6.1.3.2 eingeführte Beobachtungsregel

$$\text{Action} \longrightarrow \mathcal{P}_0 \langle 1.0 \rangle .$$

Als revidierte Hypothesenstärken ergeben sich folglich nach Anwendung der nicht-modifizierten Beobachtungsregeln für MakeSauceCarbonara, MakeMarinara, MakeSauce und Action, wie sie in den vorangegangenen Abschnitten definiert wurden (siehe Seiten 134, 137, 141, 143).

$$\tilde{r}_1(X) = \begin{cases} 0.10, & X = \{ \text{MakeFettuciniMarinara}, \text{MakeChickenMarinara} \} \\ 0.10, & X = \mathcal{P}_0 \setminus \{ \text{StackBlocks} \} \\ 0.80, & X = \mathcal{P}_0 \\ 0.00, & \text{sonst} \end{cases}$$

$$\tilde{r}_2(X) = \begin{cases} 0.15, & X = \{ \text{MakeSpaghettiCarbonara} \} \\ 0.15, & X = \mathcal{P}_0 \setminus \{ \text{StackBlocks} \} \\ 0.70, & X = \mathcal{P}_0 \\ 0.00, & \text{sonst} \end{cases}$$

$$\tilde{r}_3(X) = \begin{cases} 0.50, & X = M(\text{MakeMeatDish}) \cup M(\text{MakePastaDish}) \\ 0.50, & X = \mathcal{P}_0 \\ 0.00, & \text{sonst} \end{cases}$$

Die akkumulierte Hypothesenstärke $\tilde{r}_{1,2,3}$ ist gegeben durch

$$\tilde{r}_{1,2,3}(X) \approx \begin{cases} 0.086, & X = \{ \text{MakeFettuciniMarinara}, \text{MakeChickenMarinara} \} \\ 0.137, & X = \{ \text{MakeSpaghettiCarbonara} \} \\ 0.493, & X = M(\text{MakeMeatDish}) \cup M(\text{MakePastaDish}) \\ & \quad (= M(\text{PrepareMeal})) \\ 0.284, & X = \mathcal{P}_0 \\ 0.000, & \text{sonst} \end{cases}$$

Hypothese	m_1'''	$Bel_{m_1'''}$	$Pl_{m_1'''}$
MakeSpaghettiCarbonara	0.1370	0.1370	0.9140
MakeFettuciniAlfredo	0.0000	0.0000	0.7770
MakeFettuciniMarinara	0.0688	0.0688	0.8630
MakeChickenMarinara	0.0000	0.0000	0.1726
MakeChickenPrimavera	0.0000	0.0000	0.1554
StackBlocks	0.0000	0.0000	0.0568
MakePastaDish	0.6216	0.8274	1.0000
MakeMeatDish	0.0000	0.0000	0.1726
PrepareMeal	0.0986	0.9432	1.0000
TopLevelAct	0.0568	1.0000	1.0000

Tabelle 6.5: Die durch m_1''' induzierten Vertrauensintervalle für die Pläne aus \mathcal{H} .

Die aktualisierte Hypothesenbewertung $m_1''' := m_0 \oplus \tilde{r}_{1,2,3}$ hat somit die folgenden Werte:

$$m_1'''(X) \approx \begin{cases} 0.0688, & X = \{ \text{MakeFettuciniMarinara} \} \\ 0.1370, & X = \{ \text{MakeSpaghettiCarbonara} \} \\ 0.0172, & X = \{ \text{MakeFettuciniMarinara}, \text{MakeChickenMarinara} \} \\ 0.6216, & X = \text{MakePastaDish} \\ 0.0986, & X = \text{PrepareMeal} \\ 0.0568, & X = \text{TopLevelAct} \\ 0.0000, & \text{sonst} \end{cases}$$

Bezogen auf die in der Abstraktionshierarchie enthaltenen Planhypothesen, ergeben sich die in Tabelle 6.5 angegebenen Vertrauensintervalle.

6.2.1.5.2 Unzuverlässige Beobachtungen

Es wird angenommen, daß der Grad der Zuverlässigkeit der Aussagen eines Beobachters quantifiziert werden kann.

Definition 6.2.2 (“discounting”) [Lowrance *et al.*, 1986]

Sei $m : 2^\Omega \rightarrow [0, 1]$ eine Basiswahrscheinlichkeit, $\alpha \in [0, 1]$ der *Grad der Zuverlässigkeit* der Informationsquelle, aus der m stammt. Dann wird die Operation, die aus m eine

modifizierte Basiswahrscheinlichkeit $m^{\% \alpha}$ macht mit

$$m^{\% \alpha}(X) = \begin{cases} \alpha \cdot m(X), & X \neq \Omega \\ (1 - \alpha) + \alpha \cdot m(X), & X = \Omega \end{cases}$$

als *Discounting* bezeichnet.

Die Unzuverlässigkeit der zugrundeliegenden Information wird dadurch kompensiert, daß ein Teil der den verschiedenen Fokalelementen von m zugewiesenen Evidenzmasse der unspezifischsten aller Hypothesen Ω zugeordnet wird. Ist die Information vollständig unzuverlässig (d.h. $\alpha = 0$), so wird aus m die "leere" Basiswahrscheinlichkeit mit $m^{\%0}(\Omega) = 1$. Ist hingegen $\alpha = 1$, so wird die Information als zuverlässig betrachtet, und $m^{\%1} = m$.

Für die drei Beobachter aus dem vorhergehenden Abschnitt seien die Zuverlässigkeitsgrade 0.1, 0.5 bzw. 0.8 gegeben. Verwendet man die resultierenden Hypothesenstärken $\tilde{r}_1^{\%0.1}$, $\tilde{r}_2^{\%0.5}$ und $\tilde{r}_3^{\%0.9}$ zur Berechnung der akkumulierten Hypothesenstärke, so ergibt sich

$$\tilde{r}_{1,2,3}^{\%}(X) \approx \begin{cases} 0.0743, & X = \{ \text{MakeSpaghettiCarbonara} \} \\ 0.000926, & X = \{ \text{MakeFettuciniMarinara}, \text{MakeChickenMarinara} \} \\ 0.416262, & X = \text{PrepareMeal} \\ 0.500175, & X = \text{TopLevelAct} \\ 0.0000, & \text{sonst} \end{cases}$$

Die Kombination mit der Vorabbewertung m_0 ergibt

$$m_1^{\prime\prime\prime}(X) \approx \begin{cases} 0.000741, & X = \{ \text{MakeFettuciniMarinara} \} \\ 0.0743, & X = \{ \text{MakeSpaghettiCarbonara} \} \\ 0.00185, & X = \{ \text{MakeFettuciniMarinara}, \text{MakeChickenMarinara} \} \\ 0.73315, & X = \text{MakePastaDish} \\ 0.08235, & X = \text{PrepareMeal} \\ 0.100035, & X = \text{TopLevelAct} \\ 0.0000, & \text{sonst} \end{cases}$$

Die mangelnde Zuverlässigkeit der einzelnen Beobachtungen führt hier zu einer Konzentration der Evidenzmasse auf der unspezifischsten Hypothese in der akkumulierten Hypothesenstärke und somit im wesentlichen zu einer Bestätigung der Vorabbewertung m_0 durch die aktualisierte Hypothesenbewertung $m_1^{\prime\prime\prime}$ in dem Sinne, daß die Fokalelemente von m_0 ihre hohen Bewertungen beibehalten und allen anderen Hypothesen nur geringe Vertrauensgrade zugewiesen werden (siehe auch Tabelle 6.6)

Hypothese	m_1'''	$Bel_{m_1'''}$	$Pl_{m_1'''}$
MakeSpaghettiCarbonara	0.0743	0.0743	1.0000
MakeFettuciniAlfredo	0.0000	0.0000	1.0000
MakeFettuciniMarinara	0.000741	0.000741	1.0000
MakeChickenMarinara	0.0000	0.0000	1.0000
MakeChickenPrimavera	0.0000	0.0000	1.0000
StackBlocks	0.0000	0.0000	0.100035
MakePastaDish	0.73315	0.808191	1.0000
MakeMeatDish	0.0000	0.0000	0.184235
PrepareMeal	0.08235	0.8999	1.0000
TopLevelAct	0.100035	1.0000	1.0000

Tabelle 6.6: Die durch m_1''' induzierten Vertrauensintervalle für die Pläne aus \mathcal{H} .

6.2.1.6 Indirekte Beobachtungen und Verkettung von Beobachtungsregeln

Eine Ursache für den in Abschnitt 6.2.1.4 behandelten Typ unsicherer Evidenzen, bei dem verschiedene Alternativen mit einer Basiswahrscheinlichkeit c mit mehreren Fokalelementen auf dem Evidenzenraum Θ bewertet wurden, können *indirekte Beobachtungen* sein. Beispielsweise ist nicht in jeder Anwendung gewährleistet, daß die Aktion eines Agenten direkt beobachtbar ist. Vielmehr kann es vorkommen, daß dem Beobachter nur Veränderungen in der Welt zugänglich sind, aus denen zunächst auf mögliche verursachende Aktionen des Agenten geschlossen werden muß, um erst dann diese Aktionen auf Pläne abbilden zu können.

Die Identifizierung möglicher Aktionen auf der Basis solcher Beobachtungen erfolgt prinzipiell nach demselben Schema wie die bisher beschriebene Planerkennung selbst. Eine Menge von Regeln bildet Veränderungen in der Welt – dargestellt in einem Ereignisraum – auf verursachende Aktionen ab und induziert somit eine Basiswahrscheinlichkeit auf dem Evidenzenraum der Aktionen. Solche indirekten Beobachtungen können prinzipiell über beliebig viele Ereignisräume hinweg “transportiert” werden. Ein dem hier beschriebenen Ansatz ähnliches Schema ist im System Gister [Lowrance *et al.*, 1986] auf der Basis sogenannter “Kompatibilitätsrelationen” implementiert.

Um den Mechanismus der Regelverkettung zu untersuchen, seien die Ereignisräume Θ_W (zur Beschreibung von Veränderungen in der Welt), Θ (der die verschiedenen Aktionen enthaltende Raum) und \mathcal{P}_0 (der Hypothesenraum) gegeben sowie die beiden Δ -Partitionierungen $\mathcal{C}(\Theta_W)$ und $\mathcal{C}(\Theta)$. Ferner existierten die beiden Beobachtungsre-




Abbildung 6.11: Zwei Beobachtungsregeln in einem Szenario mit indirekter Beobachtung.

geln

$$R_1 = \{s_A^W \mid \Theta_W \supseteq A \in \mathcal{C}(\Theta_W)\}, \quad R_2 = \{s_A \mid \Theta \supseteq A \in \mathcal{C}(\Theta)\}.$$

Zunächst sollen eventuell existierende Constraints bei der Regelanwendung außer acht gelassen werden.

Sei nun als (indirekte) Evidenz eine Basiswahrscheinlichkeit $e : 2^{\Theta_W} \rightarrow [0, 1]$ gegeben. Gemäß Definition 5.1.4 induziert diese (gemeinsam mit R_1) eine Hypothesenstärke

$$r'(X) = \sum_{A \in \mathcal{C}(\Theta_W)} s_A^W(X) e_{\mathcal{C}(\Theta_W)}(A)$$

für alle $X \subseteq \Theta$. Dabei ist $e_{\mathcal{C}(\Theta_W)}$ die gemäß Definition 6.1.6 durch e und $\mathcal{C}(\Theta_W)$ induzierte Basiswahrscheinlichkeit. r' entspricht in einem Szenario wie dem in Abschnitt 6.2.1.4 beschriebenen der dort angegebenen Basiswahrscheinlichkeit c . Die Anwendung der von Θ ausgehenden Beobachtungsregel R_2 führt schließlich zur Bewertung

$$\begin{aligned} r(X) &= \sum_{A \in \mathcal{C}(\Theta)} s_A(X) r'_{\mathcal{C}(\Theta)}(A) \\ &= \sum_{A \in \mathcal{C}(\Theta)} \sum_{A' \in \mathcal{C}(\Theta_W)} s_A(X) s_{A'}^W(X) e_{\mathcal{C}(\Theta_W)}(A') \end{aligned}$$

der Planhypothesen in \mathcal{P}_0 .

Definition 6.2.3 (Verkettung)

In der gegebenen Situation ist die *Verkettung* der beiden Beobachtungsregeln R_1 und




Abbildung 6.12: Dieselben Regeln nach der Verketzung.

R_2 definiert als $R_{1,2} = \{s_A^+ \mid \Theta_W \supseteq A \in \mathcal{C}(\Theta_W)\}$ mit

$$s_A^+ : 2^{\mathcal{P}_0} \rightarrow [0, 1]$$

$$X \mapsto \sum_{A' \in \mathcal{C}(\Theta)} s_{A'}(X) \widehat{s_A^W}(A').$$

Dabei ist $\widehat{s_A^W}$ die durch s_A^W und $\mathcal{C}(\Theta)$ auf Θ induzierte Basiswahrscheinlichkeit gemäß Definition 6.1.6.

Diese Definition liefert ein Verfahren zur ‘‘Kompilierung’’ zweier Beobachtungsregeln in eine einzige Regel, wodurch erhebliche Laufzeitgewinne erreicht werden, wenn die Zwischenergebnisse – in diesem Fall also die Bewertung von Θ – nicht von direktem Interesse sind. Existieren jeweils Constraints zwischen den Elementen zweier in einer solchen Verketzung aufeinanderfolgenden Ereignisräume, so ist diese Kompilierung weniger sinnvoll, da prinzipiell alle möglichen Modifikationen der einzelnen Regeln in Abhängigkeit der Constraints miteinander verkettet werden müßten, was zu einer kombinatorisch ansteigenden Zahl zu verwaltender Beobachtungsregeln führen würde.

Beispiel: Gegeben seien $\Theta_W = \{a, b\}$, $\Theta = \{x, y\}$ und $\mathcal{P}_0 = \{h_1, h_2\}$, $\mathcal{C}(\Theta_W) = 2^{\Theta_W}$, $\mathcal{C}(\Theta) = 2^\Theta$. Die Beobachtungsregeln seien gemäß Abbildung 6.11 gegeben. Das Ergebnis der Verketzung ist in Abbildung 6.12 dargestellt. Interpretiert man Abbildung 6.11 als gerichteten Graphen, so erhält man die Regelgewichte $s_A^+(H)$ der Verketzung, indem man die Gewichte an den Kanten entlang der Pfade von A nach H miteinander multipliziert und anschließend über alle solchen Pfade summiert.

6.2.2 Interpretation der Ergebnisse

Das Ergebnis der Verarbeitung von Beobachtungen, wie sie in Abschnitt 6.2.1 beschrieben wurde, ist jeweils eine numerische Bewertung der vorhandenen Planhypothesen. Die ursprüngliche Motivation zu Berechnung einer solchen Bewertung war, auf der Basis dieser numerischen Werte eine Reihenfolge der Planhypothesen gemäß eines zu definierenden Qualitätskriteriums festzulegen, um gegebenenfalls die am besten bewertete Hypothese auswählen zu können. Der folgende Abschnitt beschäftigt sich mit der Frage, wie mit einer Basiswahrscheinlichkeit solche Kriterien definiert werden können, bevor Abschnitt 6.2.2.2 die Rechtfertigung getroffener Entscheidungen gegenüber dem Anwender eines solchen Systems untersucht.

6.2.2.1 Auswahl von Planhypothesen

Einer der am häufigsten angesprochenen Kritikpunkte an der Dempster-Shafer Theorie ist das Fehlen eines eindeutigen Kriteriums zur Entscheidungsunterstützung. Ursache dafür ist die Tatsache, daß Vertrauensgrade durch drei verschiedene, inhaltlich jedoch äquivalente Funktionen (Basiswahrscheinlichkeiten, Belief- und Plausibilitätsfunktionen) repräsentiert werden, wodurch Ereignissen kein punktueller Wert, sondern ein *Vertrauensintervall* $[Bel_m(\cdot), Pl_m(\cdot)]$ zugewiesen wird. Diesem “Defizit” ist jedoch entgegenzuhalten:

“[...] when such intervals overlap and cannot be ordered, this fact simply reflects a basic deficiency in our knowledge” [Ruspini *et al.*, 1992].

Dies bedeutet, daß der Vorteil der expliziten Repräsentation partieller Unwissenheit i.a. mit dem Verlust der eindeutigen Entscheidungsfindung einhergeht. Als eine Folge dieser Situation ist es möglich, eigene Entscheidungskriterien zu definieren, die die vorhandenen numerischen Werte mittels gewisser Heuristiken miteinander kombinieren.

Dem gegenüber steht der Nachteil der Bayesschen Wahrscheinlichkeitstheorie, daß die zur Entscheidungsfindung herangezogenen numerischen Werte stark von der Wahl des Ereignisraums abhängen, während diese bei der Dempster-Shafer Theorie eine geringere Rolle spielt (vergleiche dazu [Wilson, 1993]).

Das “Standardverfahren” zur Entscheidungsfindung nach [Dempster, 1967] beruht auf der Interpretation einer Belief-Funktion als eine kompakte Repräsentation einer konvexen Menge \mathcal{K} von Wahrscheinlichkeiten, die mit dieser kompatibel sind (d.h. $Bel(X) \leq P(X) \leq Pl(X)$ für $P \in \mathcal{K}$). Bei einer gegebenen Nutzenfunktion U kann dann eine untere Schranke für den erwarteten Nutzen für alle $P \in \mathcal{K}$ berechnet und als Entscheidungsgrundlage verwendet werden:

$$E_*[U] = \inf_{P \in \mathcal{K}} P \cdot U.$$

Eine Alternative dazu bietet die in [Smets, 1988] vorgestellte *pignistische Wahrscheinlichkeit*.

Definition 6.2.4 (pignistische Wahrscheinlichkeit)

Sei $m : 2^\Omega \rightarrow [0, 1]$ eine Basiswahrscheinlichkeit. Dann heißt die Funktion

$$P_0 : 2^\Omega \rightarrow [0, 1]$$

$$X \mapsto \sum_{A \subseteq \Omega} m(A) \frac{|A \cap X|}{|A|}$$

die durch m induzierte pignistische Wahrscheinlichkeit.

Anmerkung: Für die einzelnen Elemente $x \in \Omega$ ergibt sich

$$P_0(\{x\}) = \sum_{A: x \in A} \frac{m(A)}{|A|}.$$

P_0 verteilt somit die einem Ereignis $A \subseteq \Omega$ zugewiesene Vertrauensmasse $m(A)$ gleichmäßig an dessen Elemente.

Dieses Vorgehen, die Vertrauensintervalle zu Punkten zu verkleinern, induziert einerseits zwar wieder die bereits den punktwertigen Wahrscheinlichkeitsfunktionen inhärenten Probleme wie Abhängigkeit von der Wahl des Ereignisraums, jedoch bleibt hier die durch m repräsentierte Unwissenheit weiterhin verfügbar. Außerdem wird in [Wilson, 1993] gezeigt, daß die – einfachere – Verwendung der pignistischen Wahrscheinlichkeit zu denselben Erwartungswerten führt wie das o.a. Standardverfahren. Die Wahl, die Entscheidung für eine der Planhypothesen eines Planerkenners auf P_0 zu stützen (also diejenige mit maximaler pignistischer Wahrscheinlichkeit auszuwählen), ist somit gerechtfertigt.

Beispiel: Am Fall der Hypothesenbewertung m_1''' aus Abschnitt 6.2.1.5 soll das Vorgehen verdeutlicht werden. Für die Hypothese { MakeSpaghettiCarbonara } ergibt sich etwa

$$P_0(\{ \text{MakeSpaghettiCarbonara} \}) = 0.137 + 0.6216/3 + 0.0986/5 + 0.0568/6$$

$$\approx 0.37342.$$

Für die übrigen elementaren Hypothesen ergeben sich folgende Werte:

$$P_0(\{ \text{MakeFettuciniAlfredo} \}) \approx 0.23642$$

$$P_0(\{ \text{MakeFettuciniMarinara} \}) \approx 0.31382$$

$$P_0(\{ \text{MakeChickenMarinara} \}) \approx 0.03782$$

$$P_0(\{ \text{MakeChickenPrimavera} \}) \approx 0.07652$$

$$P_0(\{ \text{StackBlocks} \}) \approx 0.0095.$$

Zum gegenwärtigen Zeitpunkt fiel die Wahl somit auf MakeSpaghettiCarbonara.

Anmerkung: Bei allen möglichen Entscheidungskriterien besteht gegenüber der klassischen Wahrscheinlichkeitstheorie, die ausschließlich mit punktuellen Werten arbeitet, der Vorteil, daß der einer Hypothesenbewertung inhärente *Grad der Nichtspezifität* (siehe Definition 6.3.4) und damit die Unsicherheit bzgl. dieser Bewertung selbst verfügbar sind. Somit können gegebenenfalls Entscheidungen solange verschoben werden, bis zusätzliche Information vorhanden ist, die die Verteilung von Vertrauenswerten an die verschiedenen Hypothesen auf eine sicherere Grundlage stellt.

6.2.2.2 Erklärung von Entscheidungen

Eines der wichtigsten Kriterien, das die Akzeptanz von durch Computersysteme getroffenen Entscheidungen durch Anwender beeinflußt, ist deren Fähigkeit, diese Entscheidungen begründen und erklären zu können. Die einfachste Art, dies zu tun, wäre die Auflistung sämtlicher angewandter Regeln, was jedoch – zumal in Verbindung mit den numerischen Unsicherheitswerten – von einem Benutzer kaum nachvollziehbar sein dürfte. Im folgenden sollen daher kurz zwei Methoden vorgestellt werden, die einerseits diesen Aspekt der Unsicherheit, andererseits die hierarchische Struktur des Hypothesenraumes berücksichtigen.





Abbildung 6.13: Analysegraph für *eine* Beobachtung.

Die in [Strat, 1987] vorgestellte Methode beruht auf einer sogenannten “*Empfindlichkeitsanalyse*” (*sensitivity analysis*). Dazu wird zunächst aufgrund der zu berücksichtigenden Information ein *Analysegraph* konstruiert, dessen Knoten Ereignisräume mit ihren jeweiligen Bewertungen repräsentieren, und dessen Kanten die Übergänge dazwischen durch die Operationen “FUSE” (Kombination mit Dempsters Regel), “TRANSLATE” (Anwendung einer Kompatibilitätsrelation zwischen Ereignisräumen) usw. darstellen.

Abbildung 6.13 zeigt einen solchen Analysegraph für den ersten Schritt der Planerkennung mit initialer Hypothesenbewertung m_0 , revidiertem Regelgewicht \tilde{s}_1 und resultierender Hypothesenstärke \tilde{r}_1 sowie die sich ergebende aktuelle Hypothesenbewertung m_1 . Es kam dabei nur eine Regel zur Anwendung. Der durch sie induzierte Übergang vom Evidenzen- zum Hypothesenraum wurde hier durch TRANSLATE angedeutet. Diese beiden Konzepte sind nicht miteinander identisch, ihre genaue Unterscheidung spielt aber in diesem Zusammenhang keine Rolle (siehe dazu [Strat, 1987]).

Abbildung 6.14: Modifizierter Analysegraph für *eine* Beobachtung.

Um nun beispielsweise eine Benutzeranfrage bzgl. der Begründung einer Entscheidung beantworten zu können, wird diejenige Evidenz ausgewählt, die die betreffende Hypothese am stärksten unterstützt (im aktuellen Fall also m_0 oder \tilde{r}_1). Diese wird dann verbalisiert und dem Benutzer ausgegeben.

Zur Berechnung dieser Evidenz wird der aktuelle Analysegraph wie in Abbildung 6.14 modifiziert. Alle in Frage kommenden Evidenzen werden mit Hilfe der Operation DISCOUNT gewichtet. Wie bereits in Abschnitt 6.2.1.5.2 erläutert, dient diese Operation im System Gister [Lowrance *et al.*, 1986] eigentlich dazu, den Einfluß von Informationen relativ zu ihrer Zuverlässigkeit zu reduzieren, indem von einer Basiswahrscheinlichkeit m über einem Ereignisraum Ω zu

$$m^{\% \alpha}(X) = \begin{cases} \alpha \cdot m(X), & X \neq \Omega \\ (1 - \alpha) + \alpha \cdot m(X), & X = \Omega \end{cases} \quad (6.25)$$

übergegangen wird (siehe auch Definition 6.2.2). Der Faktor $\alpha = 1$ steht für absolute Zuverlässigkeit, während $\alpha = 0$ aus m die leere Basiswahrscheinlichkeit macht. Im Beispiel sind die Zuverlässigkeitsfaktoren für m_0 und \tilde{r}_1 mit α_1 bzw. α_2 bezeichnet.

Kombiniert man zwei solcher modifizierten Basiswahrscheinlichkeiten, so wird die entstehende Belieffunktion \widehat{Bel} eine Funktion der beiden Parameter α_1 und α_2 . Die partiellen Ableitungen

$$B_1(X) = \left. \frac{\partial \widehat{Bel}}{\partial \alpha_1} \right|_{\alpha_i=1}, \quad B_2(X) = \left. \frac{\partial \widehat{Bel}}{\partial \alpha_2} \right|_{\alpha_i=1}$$

dieser Funktion nach dem jeweiligen Zuverlässigkeitsparameter, evaluiert an der Stelle $\alpha_i = 1$ ($i = 1, 2$), repräsentiert die Veränderung des Belief-Wertes relativ zu einer Veränderung der Zuverlässigkeit der beiden Quellen (B_1 für m_0 und B_2 für \tilde{r}_1). Der Wert 1 für α_i muß gewählt werden, weil dies der ursprünglichen Kombination der unveränderten Basiswahrscheinlichkeiten entspricht.

Der größere dieser beiden Werte entscheidet, welche der beiden Quellen eine bestimmte Hypothese stärker unterstützt. Entsprechende Analysen können ebenso für die Plausibilitätsfunktion und andere Faktoren durchgeführt werden, deren Auswertung jeweils die Beantwortung unterschiedlicher Benutzeranfragen erlaubt.

Dieses extrem aufwendige Verfahren, das prinzipiell in jedem Schritt bei jeder Kombination zweier Basiswahrscheinlichkeiten anzuwenden ist, erlaubt die detaillierte Beantwortung unterschiedlicher Anfragen des Benutzers bzgl. des Ergebnisses der Evaluierung einer Evidenz. Da allerdings ein solcher Rechenaufwand nicht immer zu vertreten ist, wird im Expertensystem GERTIS [Yen, 1989] ein einfacheres Verfahren angewandt (siehe dazu auch Abschnitt 5.1).

GERTIS arbeitet mit einer Hierarchie medizinischer Hypothesen für bestimmte Krankheitsbilder. Will ein Anwender Näheres zur Bewertung einer bestimmten Hypothese wissen, so wird folgendes Verfahren angewandt.

1. Alle Regeln, die die betreffende Diagnose (Hypothese) direkt unterstützen oder dieser widersprechen, werden aufgelistet.
2. Die Schlußfolgerungen über die Oberklassen dieser Diagnose werden beschrieben. Diese umfassen im wesentlichen die diesen zugeordneten Vertrauensintervalle.
3. Der Anwender erhält die Möglichkeit, über diese Oberklassen weitere Information zu verlangen.

Yen erhebt den Anspruch, daß dieses Erklärungsverfahren der umgekehrten Strategie entspricht, die bei der Diagnose angewandt wird – nämlich Einschränken allgemeiner Krankheitsklassen, bis konkrete Instanzen übrigbleiben – und aufgrund der dynamischen Bestimmung der auszugebenden Regeln aufgrund der Historie der aktuellen Diagnose den konkreten Sachverhalt adäquat widerspiegelt.

Dieses Verfahren läßt sich nicht direkt auf den hier beschriebenen Ansatz zur Bewertung der Hypothesen eines Planerkennters anwenden, da besonders während der ersten Erkennungszyklen die vorhandenen Beobachtungsregeln noch sehr unspezifisch sind in dem Sinne, daß ihre Regelgewichte relativ große Hypothesenmengen als Fokalelemente besitzen. Es ist daher oftmals der Fall, daß überhaupt keine Einzelhypothesen direkt durch eine Beobachtung unterstützt werden (siehe dazu Abschnitt 6.1.3.2). Dieser Einfluß wird nur indirekt ausgeübt durch die Durchschnittsbildung von Hypothesenmengen bei der Kombination zweier Basiswahrscheinlichkeiten sowie die "Projektion" der Vertrauensintervalle abstrakter Hypothesen auf die Einzelhypothesen bei der Berechnung der pignistischen Wahrscheinlichkeit als Entscheidungskriterium (siehe Definition 6.2.4).

Es ist daher notwendig, den Einfluß der Beobachtungsregeln auf dieses Kriterium zu untersuchen und u.U. vor der Anwendung der drei o.a. Schritte die Regelgewichte der angewandten Beobachtungsregeln in eine solche pignistische Wahrscheinlichkeit zu transformieren. Für den Fall der Regel für die Beobachtung MakeMarinara auf

Seite 134 ergeben sich beispielsweise die Werte

$$P_0(\{x\}) = \begin{cases} 0.35, & x = \text{MakeFettuciniMarinara} \\ 0.35, & x = \text{MakeChickenMarinara} \\ 0.00, & x = \text{StackBlocks} \\ 0.10, & \text{sonst} \end{cases}$$

6.3 Das quantitative Benutzermodell

In diesem Abschnitt werden Mechanismen vorgestellt, um ein quantitatives Benutzermodell zu initialisieren und zu warten. Die darin enthaltene Information über

- Präferenzen eines Agenten in bezug auf eine Menge möglicher Pläne und
- das gemeinsame Auftreten bestimmter Aktionen und Pläne im Verhalten des Agenten

(siehe dazu auch Abschnitt 6.1.2) wird jeweils durch Basiswahrscheinlichkeiten aus der Dempster-Shafer Theorie repräsentiert. Neben der bereits erwähnten Möglichkeit, eine initiale Hypothesenbewertung durch die ‐leere‐ Basiswahrscheinlichkeit zu repräsentieren (siehe Abschnitt 6.1.3.1) bzw. Regelgewichte heuristisch zu initialisieren (siehe Abschnitt 6.1.3.2), wird in 6.3.1 ein Verfahren auf der Basis der linearen Programmierung vorgestellt, das aus einer Menge von Abschätzungen für die induzierten Vertrauensintervalle eine geeignete Basiswahrscheinlichkeit berechnet. Neben dieser Initialisierung werden in Abschnitt 6.3.2 Operationen vorgestellt, um diese Informationen im Anschluß an den Erhalt zusätzlicher Informationen zu aktualisieren.

6.3.1 Berechnung einer Basiswahrscheinlichkeit aus Intervallabschätzungen

Die bereits angesprochene Fähigkeit der Dempster-Shafer-Theorie, Unsicherheit mittels Vertrauensintervallen anstelle von Punkten zu repräsentieren, erlaubt es, in Anwendungen, in denen kein exaktes statistisches Material zur Verfügung steht, eine Situation in einer dem aktuellen Wissensstand entsprechenden Granularität zu modellieren (vgl. [Dempster, 1967; Shafer, 1976]). Im Gegensatz zur Wahrscheinlichkeitstheorie genügt es, obere und untere Schranken für die Wahrscheinlichkeit einiger Ereignisse anzugeben und den Rest unspezifiziert zu lassen, anstatt u.U. ungerechtfertigte Unabhängigkeitsannahmen einzuführen oder Prinzipien wie *maximale Entropie* anzuwenden, die die gegebene Information künstlich vervollständigen. Es ist somit möglich, die Entscheidung für eine bestimmte Wahrscheinlichkeitsfunktion solange zu verschieben, bis vollständige Informationen vorhanden sind. Bis dahin können alle solche Funktionen, die in einer einzigen Belieffunktion kodiert sind, als Hypothese

für den “wahren” Wert der vorhandenen Wahrscheinlichkeitsverteilung beibehalten werden.⁴

In [Lemmer und Kyburg, 1991] wurde bereits bemerkt:

“many people are more comfortable with interval estimates than real-valued estimates.”

Die Konsistenz einer solchen Menge von Intervallabschätzungen zu überprüfen und gegebenenfalls eine entsprechende Basiswahrscheinlichkeit zu konstruieren, ist jedoch eine nicht-triviale Aufgabe. *Konsistenz* heißt dabei, daß es mindestens eine Basiswahrscheinlichkeit m gibt, die alle Intervalle erfüllt in dem Sinn, daß die entsprechenden Funktionen Bel_m und Pl_m exakt diese Vertrauensintervalle realisieren. Darüberhinaus stellen sich zwei weitere Fragen: Wie kann m berechnet werden und – falls mehr als eine Lösung existiert – wie gelangt man zu einem Resultat, das gewisse wünschenswerte Eigenschaften besitzt (ähnlich der maximalen Entropie in der Wahrscheinlichkeitstheorie)?

Das erste dieser Probleme wurde bereits von Lemmer und Kyburg in [Lemmer und Kyburg, 1991] behandelt. Während der dort beschriebene Algorithmus sich jedoch auf den Fall von Intervallabschätzungen für *atomare Ereignisse* beschränkt, wird im folgenden eine Prozedur beschrieben, die den allgemeinen Fall behandelt.

Der Rest dieses Abschnitts gliedert sich wie folgt: In Abschnitt 6.3.1.1 werden zunächst die mathematischen Voraussetzungen für die vorgestellten Algorithmen geschaffen. 6.3.1.2 präsentiert dann die Lösung des Problems, eine Basiswahrscheinlichkeit zu konstruieren, die eine Menge solcher Intervallvorgaben erfüllt, wobei auch auf die Komplexität dieser Berechnung und die speziellen Eigenschaften des Resultats eingegangen wird. Abschnitt 6.3.1.3 führt zunächst ein Unsicherheitsmaß ein, das zur Bewertung der “Qualität” einer Lösung benutzt werden kann und stellt dann einen Algorithmus vor, der ein bzgl. dieses Kriteriums optimales Ergebnis liefert. Es wird außerdem gezeigt, wie andere Gütekriterien mit minimalem Aufwand vom gleichen Algorithmus erfüllt werden können.

6.3.1.1 Mathematische Voraussetzungen

Einen Schwerpunkt bei der Lösung der o.a. Probleme bildet die sog. *lineare Programmierung*, die sich mit der Minimierung einer linearen Funktion unter Einhaltung einer Menge von Randbedingungen beschäftigt. Im folgenden stehen fettgedruckte Großbuchstaben wie \mathbf{A} und \mathbf{A}_1 für Matrizen und Kleinbuchstaben wie \mathbf{c} , \mathbf{i} für Vektoren.⁵

Sei $c : \mathbb{R}^n \rightarrow \mathbb{R}$, $(x_1, \dots, x_n) \mapsto c_1x_1 + \dots + c_nx_n$ eine lineare Funktion, die sogenannte *Zielfunktion*. In Vektornotation erhält man dafür $\mathbf{c}^T \mathbf{x}$ mit einem n -dimensionalen

⁴In [Kyburg, 1987] wird gezeigt, daß eine Belieffunktion einer konvexen Menge von Wahrscheinlichkeitsfunktionen entspricht.

⁵Für eine detaillierte Einführung in das Gebiet der linearen Programmierung sei auf [Chvátal, 1983] verwiesen.

Zeilenvektor \mathbf{c}^T . $\mathbf{A} \in \mathbb{R}^{k \times n}$ sei die Koeffizientenmatrix eines linearen Gleichungssystems, $\mathbf{x}, \mathbf{b} \in \mathbb{R}^n$.

Definition 6.3.1 (Standardform)

Die *Standardform eines linearen Programmierungsproblems* in Vektornotation ist:

$$\text{minimiere } \mathbf{c}^T \mathbf{x},$$

$$\text{wobei } \mathbf{A} \mathbf{x} = \mathbf{b} \text{ und } \mathbf{x}, \mathbf{b} \geq 0.$$

Die letzte Bedingung bedeutet, daß jede einzelne Komponente von \mathbf{x} und \mathbf{b} nichtnegativ ist.

Definition 6.3.2 (Basis, Basislösung)

Sei r_0 der Rang von \mathbf{A} . Eine *Basis* ist dann eine Auswahl von r_0 linear unabhängigen Spalten von \mathbf{A} . Die diesen Spalten entsprechenden Variablen werden als *Basis-*, alle anderen als *Nichtbasisvariablen* bezeichnet. Eine *Basislösung* ist ein Vektor \mathbf{x}_0 mit $\mathbf{A} \mathbf{x}_0 = \mathbf{b}$, wobei alle Nichtbasisvariablen den Wert 0 haben. Sie heißt *zulässig*, wenn alle Basisvariablen nichtnegative Werte erhalten haben.

Satz 6.3.1 (Fundamentalsatz der linearen Programmierung)

- (a) Wenn ein lineares Programmierungsproblem P eine zulässige Lösung besitzt, dann besitzt es auch eine zulässige Basislösung.
- (b) Wenn P eine optimale zulässige Lösung besitzt, dann besitzt es auch eine optimale zulässige Basislösung.

Ein Grund für die Gültigkeit dieses Satzes liegt in der bereits erwähnten Tatsache, daß die Dimension des von den Spalten von \mathbf{A} aufgespannten Vektorraumes V genau der Dimension von \mathbf{A} entspricht und \mathbf{b} somit – im Falle der Lösbarkeit – als Linearkombination über einer Basis von V darstellbar ist.

Diese Tatsache wird im bekannten Simplex-Algorithmus zur Lösung linearer Programmierungsprobleme ausgenutzt. Die Grundidee ist dabei folgende: In einem ersten Schritt wird eine initiale zulässige Basislösung des Problems berechnet. Solange das Minimum der Zielfunktion c noch nicht erreicht ist, wird eine Basisvariable ausgewählt und durch eine Nichtbasisvariable ersetzt, so daß sich der aktuelle Wert von c vermindert. Dieser Schritt heißt *Pivotierung*. Die Auswahl der beiden an einem solchen Schritt beteiligten Variablen garantiert, daß jederzeit von einer zulässigen Basislösung zu einer anderen gewechselt wird. Der Algorithmus hält an, sobald eine optimale zulässige Basislösung gefunden wurde.

Die einfache Anwendung der Gauß-Elimination im ersten Schritt könnte zu einer nicht zulässigen Basislösung führen. Zulässigkeit kann jedoch erreicht werden, wenn k Hilfsvariablen y_1, \dots, y_k eingeführt werden und das Problem

$$\begin{aligned} &\text{minimiere } \sum_{i=1}^k y_i, \\ &\text{wobei } \mathbf{A} \mathbf{x} + \mathbf{y} = \mathbf{b} \text{ und } \mathbf{x}, \mathbf{y} \geq 0 \end{aligned} \tag{6.26}$$

stattdessen gelöst wird. Dabei ist \mathbf{y} der Vektor der Hilfsvariablen. Dieser Schritt genügt bereits, um zu entscheiden, ob das ursprüngliche Problem eine optimale zulässige Lösung besitzt.

6.3.1.2 Berechnung einer Basiswahrscheinlichkeit

Im folgenden soll der Ursprung der zugrundeliegenden Intervallabschätzungen als Äußerungen eines Domänenexperten vernachlässigt werden. Stattdessen werden sie einfach als eine Menge von *Randbedingungen bzgl. der Wahrscheinlichkeitswerte gewisser Ereignisse* bzw. als *Vertrauensintervalle* betrachtet (siehe dazu auch [Ruspini et al., 1992]). Zunächst soll die erste der o.a. Aufgaben exakt formuliert werden.

Sei eine nichtleere Menge Ω mit $|\Omega| = n$ gegeben. Ein Tripel $\langle S, l, u \rangle$ mit $\emptyset \neq S \subseteq \Omega$, $l, u \in [0, 1]$ und $l \leq u$ soll so interpretiert werden, daß die Wahrscheinlichkeit des Ereignisses S zwischen l und u liegen muß. Sei $C := \{\langle S_i, l_i, u_i \rangle \mid i = 1, \dots, k\}$ eine Menge solcher Randbedingungen mit $k \leq 2^n$. Dann kann die erste Aufgabe wie folgt formuliert werden:

T1: Berechne eine Basiswahrscheinlichkeit m auf 2^Ω , so daß für alle $1 \leq i \leq k$:
 $Bel_m(S_i) = l_i$ und $Pl_m(S_i) = u_i$.

Definition 6.3.3

Eine Basiswahrscheinlichkeit m erfüllt eine Menge von Intervallabschätzungen $C := \{\langle S_i, l_i, u_i \rangle \mid i = 1, \dots, k\}$ genau dann, wenn für alle $1 \leq i \leq k$ gilt: $Bel_m(S_i) = l_i$ und $Pl_m(S_i) = u_i$.

Im folgenden wird der Algorithmus zur Lösung von T1 vorgestellt, seine Komplexität berechnet und gezeigt, daß maximal $2k + 1$ Werte von 2^n möglichen berechnet werden müssen. Der Algorithmus besteht aus zwei Phasen, je einer zur Behandlung der l_i und u_i .

Phase 1: Zunächst werden die durch C vorgegebenen unteren Schranken l_i betrachtet. Nach dieser Phase erfüllt die resultierende Abbildung m_l die untere Hälfte der Bedingungen aus C : $Bel_{m_l}(S_i) = l_i$ für alle $1 \leq i \leq k$ (m_l ist noch keine Basiswahrscheinlichkeit, da sie die zweite Bedingung aus Definition 2.1.2 i.a. nicht erfüllt). C sei gemäß der Kardinalität der S_i geordnet, d.h. $|S_i| \leq |S_j|$, wenn $i < j$. Man erhält dann die in Abbildung 6.15 beschriebene Prozedur.

Nach dieser Phase gilt $u_i = Pl_m(S_i) - Pl_{m_l}(S_i)$ für die gesuchte Basiswahrscheinlichkeit m . Die Laufzeit kann wie folgt berechnet werden: Die Hauptschleife muß k mal durchlaufen werden, und die i -te Iteration erfordert $k + (k - i)$ Schritte. Dies ergibt eine Abschätzung von

$$O\left(\sum_{i=1}^k (k + (k - i))\right) = O\left(\frac{3k^2 - k}{2}\right). \quad (6.27)$$

Da die bisher berechneten Werte nicht mehr geändert werden, gilt bereits $m(S_i) = m_l(S_i)$.

```

for  $i := 1$  to  $k$ 
  do  $m_l(S_i) := l_i$ 
    for  $j := i + 1$  to  $k$ 
      do if  $S_i \subseteq S_j$ 
        then  $l_j := l_j - l_i$     ;; unlösbar, falls  $l_j < 0$ 
      fi
    od
  for  $j := 1$  to  $k$ 
    do if  $S_i \cap S_j \neq \emptyset$ 
      then  $u_j := u_j - l_i$     ;; unlösbar, falls  $u_j < 0$ 
    fi
  od
od

```

Abbildung 6.15: Die Prozedur für Phase 1.

Phase 2: Die zentrale Idee zur Berechnung der den u_i entsprechenden m -Werte ist es, die verbleibenden Randbedingungen $Pl_m(S_i) = u_i$ als eine Menge linearer Gleichungen zu betrachten. Nach der Definition der Plausibilitätsfunktion können diese umgeschrieben werden als $\sum_{X \cap S_i \neq \emptyset} m(X) = u_i$, was wiederum

$$\sum_{X \subseteq \Omega} \alpha_{i,X} m(X) = u_i \quad (6.28)$$

entspricht mit $\alpha_{i,X} = 1$, falls $X \cap S_i \neq \emptyset$ und 0 sonst. Identifiziert man jeden Wert $m(X)$ mit einer Variablen m_X , so kann man (6.28) in Vektornotation bringen:

$$\mathbf{A} \mathbf{m} = \mathbf{u}, \quad (6.29)$$

wobei \mathbf{A} die Koeffizientenmatrix der $\alpha_{i,X}$ ist und \mathbf{m} und \mathbf{u} die Spaltenvektoren der Variablen m_X und der Schranken u_i darstellen. Der Aufwand zur Lösung eines solchen Gleichungssystems hängt stark von der Größe von \mathbf{A} ab. Es wird deshalb im folgenden die Anzahl der Zeilen und Spalten ermittelt, die zur exakten Repräsentation dieses Problems erforderlich sind.

Dabei gibt es insgesamt drei Möglichkeiten, die Größe von \mathbf{A} zu beschränken:

1. Gemäß der Definition von Belief werden in Phase 1 indirekt mehr Werte berechnet als explizit angegeben wurde. Diese Tatsache kann zur Verringerung der Anzahl der benötigten Spalten von \mathbf{A} herangezogen werden.
2. Als Seiteneffekt der ersten Phase kann der Fall auftreten, daß gewisse Randbedingungen aus C redundant werden, was zu einer Verminderung der Zeilen von \mathbf{A} führt.

3. Durch einen einfachen Test können Spalten eliminiert werden, die *garantiert* keinen Beitrag zur Lösbarkeit des Gesamtsystems beitragen.

Nachfolgend werden diese drei Punkte diskutiert und die möglichen Einsparungen quantifiziert:

ad 1.: Phase 1 bestimmt nicht nur m -Werte für die in C explizit aufgeführten Mengen S_i , sondern indirekt auch für all ihre Teilmengen: Da die Bedingungen $Bel_m(S_i) = l_i$ durch Zuweisung von l_i an S_i (und die S_j mit $J < i$) bereits erfüllt sind, kann keine ihrer anderen Teilmengen mehr einen von 0 verschiedenen Wert erhalten, da gemäß Definition 2.1.3 gilt:

$$Bel_m(S_i) = \sum_{X \subseteq S_i} m(X).$$

Somit liegt die Anzahl der in Phase 1 tatsächlich berechneten Werte bei

$$\sum_{i=1}^k (2^{|S_i|} - 1) - \sum_{i=1}^k \sum_{j=i+1}^k (2^{|S_i \cap S_j|} - 1) \quad (6.30)$$

$$= \sum_{i=1}^k (2^{|S_i|} - \sum_{j=i+1}^k (2^{|S_i \cap S_j|} - 1)) - k. \quad (6.31)$$

Der erste Term von (6.30) ist die Anzahl aller Teilmengen aller in C aufgeführten S_i , die um die Anzahl derjenigen Mengen reduziert werden muß, die Teilmenge *mehrerer* S_j sind und somit mehrfach gezählt würden. Somit kann die Anzahl der Spalten von \mathbf{A} – d.h. die Anzahl der zu berechnenden Variablen – um den Wert von (6.31) reduziert werden.

ad 2.: Während Phase 1 können verschiedene der u_i den Wert 0 angenommen haben. Dies ist unter anderem der Fall für alle Randbedingungen mit $l_i = u_i$ in der ursprünglichen Menge C sowie für diejenigen, deren Plausibilitätswert bereits durch die Berechnung der m -Werte nachfolgender Ereignisse S_j erreicht ist. Gemäß der Definition von Plausibilität bedeutet dies, daß alle anderen Mengen mit nichtleerem Durchschnitt mit S_i nur den Wert 0 erhalten können – mit Ausnahme der Teilmengen aller S_j , deren m -Wert bereits feststeht.

Somit bestimmt eine solche Randbedingung die Werte von $2^n - 2^{|\overline{S_i}|}$ Teilmengen von Ω .⁶ Reduziert man diese Zahl um die Summe derjenigen Teilmengen, die bereits in 1. gezählt wurden, so erhält man

$$2^n - 2^{|\overline{S_i}|} - (2^{|S_i|} - 1) \quad (6.32)$$

weitere Spalten, die in \mathbf{A} nicht benötigt werden. Außerdem können natürlich die diesen Gleichungen entsprechenden Zeilen aus \mathbf{A} entfernt werden, da sie keine zusätzlichen Restriktionen bzgl. der Lösung darstellen.

ad 3.: Das lineare Gleichungssystem $\mathbf{A}\mathbf{m} = \mathbf{u}$ zu lösen, ist äquivalent dazu zu zeigen, daß \mathbf{u} im von den Spaltenvektoren von \mathbf{A} aufgespannten Vektorraum V liegt. Entfernt

⁶Zur Erinnerung: \overline{X} steht für das Komplement von X bzgl. Ω .

man also aus \mathbf{A} Spalten, die von anderen linear abhängig sind, so bleibt die Dimension von V gleich, und die Lösbarkeit des Gleichungssystems verändert sich nicht. Eine exakte Berechnung des Ranges von \mathbf{A} würde es ermöglichen, eine minimale Anzahl von linear unabhängigen Spalten, d.h. eine Basis von V , auszuwählen und dann dieses reduzierte Gleichungssystem zu lösen. Dazu wäre jedoch die komplette Berechnung der Zeilenstufenform von \mathbf{A} erforderlich, was insgesamt k Neuberechnungen der Gesamtmatrix entspricht. Durch einen einfachen Test ist es allerdings möglich, zumindest einen Teil der überflüssigen Spalten zu bestimmen, indem man sich auf diejenigen beschränkt, die ausschließlich aus Einsen bestehen. Dies sind genau diejenigen, deren zugehörige Teilmenge von Ω einen nichtleeren Schnitt mit *allen* S_i besitzt. Durch einen einfachen Test können alle diese Spalten in Laufzeit $O(|\mathbf{A}|)$ ermittelt werden, wobei $|\mathbf{A}|$ die Anzahl aller Einträge in \mathbf{A} bezeichnet. Alle bis auf eine von ihnen können aus \mathbf{A} entfernt werden, ohne deren Rang zu verändern. Mit $S := \cup_{i=1}^k S_i$ erhält man eine Gesamtsumme von

$$2^n - 1 - (2^{|\bar{S}|} - 1) + 1 = 2^n - 2^{|\bar{S}|} + 1 \quad (6.33)$$

überflüssigen Spalten von \mathbf{A} , von denen einige bereits in den beiden vorhergehenden Reduktionsschritten entfernt wurden.

Sei nun die Menge der notwendigen Variablen identifiziert (durch Anwendung der Schritte 1. – 3.), so daß sich eine Matrix $\mathbf{A} \in \mathbb{R}^{k_1 \times r}$ mit $k_1 \leq k$ und $r < 2^n$. Dann muß eine weitere Zeile hinzugefügt werden, die für die Gleichung $\sum_X m_X = 1 - \sum_i m(S_i)$ steht und die Basiswahrscheinlichkeitseigenschaft des Ergebnisses sicherstellen soll.⁷ Man erhält somit ein Gleichungssystem

$$\mathbf{A}_1 \mathbf{m}_1 = \mathbf{u}_1 \quad (6.34)$$

mit $\mathbf{A}_1 \in \mathbb{R}^{(k_1+1) \times r}$. \mathbf{u}_1 und \mathbf{m}_1 sind die entsprechenden Versionen von \mathbf{u} und \mathbf{m} , auf die dieselben Reduktionsschritte 1. – 3. angewandt wurden.

Eine zulässige Lösung von $\mathbf{A}_1 \mathbf{m}_1 = \mathbf{u}_1$ kann einfach berechnet werden durch die in (6.26) beschriebene Prozedur. Falls das Problem lösbar ist, wird eine Lösung gefunden, indem höchstens $k_1 + 1$ Variablen ein Wert ungleich Null zugewiesen wird. Andernfalls wird die Nichtexistenz einer Lösung angezeigt.

Diese Prozedur beinhaltet $k_1 + 1$ Pivotschritte, von denen jeder die Neuberechnung der Gesamtmatrix erfordert. Somit ergibt sich eine Komplexität von

$$O((k_1 + 1)^2 r). \quad (6.35)$$

Um die Gesamtkomplexität beider Phasen zu bestimmen, muß berücksichtigt werden, daß im schlechtesten Fall $k_1 = k$ gilt, d.h. daß es nach Phase 1 keine Randbedingungen mit $u_i = 0$ gibt, so daß im 2. Reduktionsschritt keine Spalten eliminiert werden konnten. Auch die Anzahl der im 3. Schritt entfernten Spalten kann Null sein. Somit ergibt sich für (6.35) eine obere Schranke von $O(k^2 r)$, wobei $r = 2^n - \langle \text{Ergebnis}$

⁷Die Werte $m(S_i) = m_l(S_i)$ wurden bereits in Phase 1 berechnet.

von (6.31)), d.h. die Anzahl der tatsächlich in der Koeffizientenmatrix auftretenden Spalten ist. Da die Komplexität der zweiten Phase die der ersten übersteigt, ergibt sich eine Gesamtlauzeit von

$$O\left(\frac{3k^2 - k}{2} + k^2r\right) = O(k^2r). \quad (6.36)$$

Bemerkungen: Es wäre möglich gewesen, die l_i ebenso wie die u_i zu behandeln durch Lösung eines entsprechenden Gleichungssystems. In diesem Fall wäre die Gesamtkomplexität jedoch

$$O(4k^2 2^n)$$

gewesen, da die Koeffizientenmatrix $2k + 1$ Zeilen und 2^n Spalten gehabt hätte.

Die Anzahl der durch diesen Algorithmus berechneten von Null verschiedenen Werte ist höchstens $2k + 1$.

Beispiel 6.3.1 Sei $C = \{\langle\{a\}, 0.1, 0.5\rangle, \langle\{b, c\}, 0.1, 0.8\rangle, \langle\{c, d\}, 0.1, 0.8\rangle\}$ eine Menge von Intervallabschätzungen über der Menge $\Omega = \{a, b, c, d\}$. Phase 1 liefert die folgenden Werte:

$$m(\{a\}) = 0.1, \quad m(\{b, c\}) = 0.1, \quad m(\{c, d\}) = 0.1. \quad (6.37)$$

Die aktuellen Werte der oberen Schranken sind $u_1 = 0.4$, $u_2 = u_3 = 0.6$. Um Phase 2 beginnen zu können, werden die Plausibilitätsbedingungen in ein lineares Gleichungssystem transformiert:

$$\begin{array}{cccccccc} & ab & ac & ad & bd & abc & abd & acd & bcd & abcd \\ \begin{pmatrix} 1 & 1 & 1 & 0 & 1 & 1 & 1 & 0 & 1 \\ 1 & 1 & 0 & 1 & 1 & 1 & 1 & 1 & 1 \\ 0 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \end{pmatrix} & \mathbf{m} & = & \begin{pmatrix} 0.4 \\ 0.6 \\ 0.6 \\ 0.7 \end{pmatrix} \end{array}$$

Der Index über den einzelnen Spalten bezeichnet die Teilmenge, für die diese Spalte steht, wobei z.B. ab eine Abkürzung für $\{a, b\}$ ist und die letzte Zeile die Tatsache repräsentiert, daß insgesamt noch ein Rest von 0.7 zu verteilen bleibt. Gemäß dem 3. Reduktionsschritt aus Phase 2 können die Spalten, die nur aus Einsen bestehen, bis auf eine entfernt werden. Entscheidet man sich dafür, die Spalten ab , ad , bd , bcd , und $abcd$ beizubehalten, so erhält man eine Matrix \mathbf{A}_1 der Größe 4×5 . Eine Lösung dieses Gleichungssystems ist

$$m(X) = \begin{cases} 0.1, & X = \{a, b\} \\ 0.1, & X = \{a, d\} \\ 0.3, & X = \{b, d\} \\ 0.2, & X = \{a, b, c, d\} \\ 0, & \text{sonst} \end{cases}$$

Zusammen mit den Werten aus (6.37) ist die Basiswahrscheinlichkeit m vollständig bestimmt.

6.3.1.3 Berechnung einer speziellen Basiswahrscheinlichkeit

Eine Menge C von Intervallabschätzungen induziert i.a. mehr als *eine* Basiswahrscheinlichkeit. Mitunter genügt es dann nicht, eine beliebige Lösung zu berechnen, sondern es existieren dann gewisse zusätzliche Anforderungen, die erfüllt werden müssen. In der Wahrscheinlichkeitstheorie ist das *Prinzip der maximalen Entropie* ein Beispiel für ein solches Kriterium, mit dessen Hilfe eine bestimmte Wahrscheinlichkeitsfunktion aus einer ganzen Klasse selektiert wird. Für Basiswahrscheinlichkeiten existiert ein ähnliches Maß für die in einer solchen Funktion implizit enthaltene Unsicherheit. Die folgende Definition geht auf die Arbeit von Dubois und Prade in [1985] zurück:

Definition 6.3.4 (Grad der Nichtspezifizität)

Für eine Basiswahrscheinlichkeit $m : 2^\Omega \rightarrow [0, 1]$ heißt

$$I(m) = \sum_{\emptyset \neq X \subseteq \Omega} m(X) \log |X| \quad (6.38)$$

der *Grad der Nichtspezifizität*.

Sei C eine Menge von Intervallabschätzungen, die eine Klasse M_C von Basiswahrscheinlichkeiten induziert. Wenn $m_0 \in M_C$ den Wert von I maximiert, so ist m_0 diejenige Basiswahrscheinlichkeit, die unter Berücksichtigung der durch C vorgegebenen Randbedingungen die wenigsten Zugeständnisse macht in dem Sinne, daß die über C hinausgehende, zusätzlich in m_0 enthaltene Information minimiert wird. Somit kann m_0 als die “exakteste” Repräsentation von C betrachtet werden. Das folgende Beispiel soll dies verdeutlichen.

Beispiel 6.3.2 Sei $C = \{\{a\}, 0.1, 0.5\}$ gegeben über der Grundmenge $\Omega = \{a, b, c\}$. Zwei mögliche Basiswahrscheinlichkeiten m_1 und $m_2 \in M_C$ sind in Abbildung 6.16 dargestellt. Für diese gelten die Werte $I(m_1) \approx 0.341$ und $I(m_2) \approx 0.120$. Untersucht man beide Funktionen, so stellt man fest, daß m_1 allen Teilmengen von Ω die maximal mögliche Plausibilität zuordnet, während bei m_2 beispielsweise die Plausibilität von $\{c\}$ den Wert Null besitzt. Dies bedeutet, daß $\{c\}$ im Ereignisraum keine weitere Rolle mehr spielt in dem Sinne, daß auch weitere Information in Form von Basiswahrscheinlichkeiten, die mit m_2 kombiniert werden, diesem Ereignis immer das Vertrauensintervall $[0, 0]$ zuordnen wird. Somit ist $\{c\}$ als möglicher Weltzustand von vornherein ausgeschlossen, obwohl dies in den Intervallabschätzungen C nicht explizit vorgesehen war.

An diesem Beispiel wurde deutlich, daß Funktionen, die ihre Masse “möglichst großen” Teilmengen von Ω zuweisen, zu bevorzugen sind, da diese die den nicht in C aufgeführten Ereignissen zugeordneten Vertrauensintervalle maximal groß halten und somit explizit das Fehlen von Information diesbezüglich repräsentieren. Dies ist wünschenswert, da – wie das obige Beispiel zeigte – zu kleine Vertrauensintervalle ungerechtfertigte Restriktionen bzgl. des Ereignisraumes darstellen können. Daher tritt die Kardinalität der einzelnen Teilmengen von Ω auch als Faktor in (6.38) auf.




Abbildung 6.16: Zwei der induzierten Basiswahrscheinlichkeiten.

Ist insbesondere eine Basiswahrscheinlichkeit m gegeben, die einer diskreten Wahrscheinlichkeitsverteilung entspricht (d.h. $m(X) = 0$ für alle X mit $|X| > 1$), so liegt keinerlei Unsicherheit bzgl. dieser Verteilung vor, und es gilt $I(m) = 0$.

Mit der Funktion I als Indikator für die “Qualität” einer Basiswahrscheinlichkeit kann nun die zu Beginn dieses Kapitels informal gestellte zweite Aufgabe exakt formuliert werden:

T2: Sei $C := \{\langle S_i, l_i, u_i \rangle \mid i = 1, \dots, k\}$ eine Menge von Intervallabschätzungen über einer Grundmenge Ω wie in Abschnitt 6.3.1.2. Berechne eine Basiswahrscheinlichkeit m auf 2^Ω , so daß für alle $1 \leq i \leq k$: $Bel_m(S_i) = l_i$ und $Pl_m(S_i) = u_i$, und $I(m)$ ist maximal unter allen Basiswahrscheinlichkeiten, die C erfüllen (vgl. Definition 6.3.3).

Im folgenden wird ein Algorithmus vorgestellt, der diese Aufgabe erfüllt. Wie bei der Lösung von T1 im vorigen Abschnitt werden dabei zwei Phasen unterschieden:

Phase 1: Dieser Schritt ist identisch mit Phase 1 des T1-Algorithmus. Es muß gezeigt werden, daß die Maximalität von I für den hier berechneten Teil von m gilt.

Offensichtlich kann jede durch C induzierte Basiswahrscheinlichkeit m in zwei Abbildungen m_l und $m_u : 2^\Omega \rightarrow [0, 1]$ aufgeteilt werden mit

1. $m_l(X) = 0$ für alle X , die *nicht* Teilmenge einer der in C aufgeführten Mengen S_i ist.
2. $m_u(X) = 0$ für alle Teilmengen der in C aufgeführten Mengen S_i .
3. $m(X) = m_l(X) + m_u(X)$ für alle $X \subseteq \Omega$.

Das heißt, m_i ist der Teil von m , aus dem die Belief-Werte der S_i berechnet werden, und der durch m_u zu einer Basiswahrscheinlichkeit m ergänzt wird. m_i ist genau der Teil von m , der in Phase 1 berechnet wird.

Lemma 6.3.1 Erweitert man Definition 6.3.4 derart, daß I auf alle Abbildungen $f : 2^\Omega \rightarrow [0, 1]$ anwendbar ist, so gilt, daß die durch Phase 1 berechnete “unvollständige” Basiswahrscheinlichkeit m_i den Wert von I maximiert unter allen Abbildungen m'_i , die die o.a. Punkte 1.–3. erfüllen.

Beweis: (Induktion über die Anzahl der Iterationen) Nach der ersten Iteration gilt $I(m_i) = l_1 \log|S_1|$. Sei nun $m'_i : 2^\Omega \rightarrow [0, 1]$ derart, daß $\sum_{X \subseteq S_1} m'_i(X) = l_1$. Dann gilt:

$$\begin{aligned} I(m'_i) &= \sum_{X \subseteq \Omega} m'_i(X) \log|X| = \sum_{X \subseteq S_1} m'_i(X) \log|X| \\ &\leq \sum_{X \subseteq S_1} m'_i(X) \log|S_1| = l_1 \log|S_1| \\ &= I(m_i) \end{aligned}$$

Für den i -ten Schritt greift ein ähnliches Argument: In den ersten $i - 1$ Schritten wurde l_i jedesmal reduziert, wenn eine Teilmenge S_j von S_i betrachtet wurde. Der gesamte Rest (l_i) wird nun $m_i(S_i)$ zugewiesen, wodurch die Optimalität gemäß der Induktionsannahme erhalten bleibt. \square

Die somit gezeigte Optimalität des Resultats von m_i ist eine lokale Eigenschaft in dem Sinne, daß sie sich nur auf den “unteren” Teil von m bezieht. Da sich m gemäß Punkt 3. der obigen Aufzählung jedoch in zwei Teilfunktionen aufspalten läßt und die in Phase 1 berechneten Werte nicht mehr verändert werden, gilt, daß eine optimale Basiswahrscheinlichkeit m diese optimale Teilfunktion beinhalten muß.

Da Phase 1 ein solches optimales m_i berechnet, ist sie somit ein korrekter Bestandteil des T2-Algorithmus.

Phase 2: Wie im entsprechenden Teil der Lösung von T1 werden die verbleibenden oberen Schranken u_i als eine Menge linearer Gleichungen repräsentiert. Zusammen mit dem Ziel, den Wert von I zu maximieren, ergibt dies ein Problem der linearen Programmierung:

$$\begin{aligned} &\text{minimiere } -\mathbf{i}^T \mathbf{m}, \\ &\text{wobei } \mathbf{A} \mathbf{m} = \mathbf{u} \text{ und } \mathbf{m} \geq 0. \end{aligned} \tag{6.39}$$

Dabei ist wiederum \mathbf{A} die aus der Übertragung der Randbedingungen in lineare Gleichungen resultierende Koeffizientenmatrix wie in (6.29), \mathbf{u} und \mathbf{m} sind die Vektoren, die als Komponenten die u_i und die Variablen m_X enthalten (vgl. auch die Lösung von T1). \mathbf{i}^T ist der Zeilenvektor, der die Nichtspezifitätsfunktion I repräsentiert:

$$I(m) = \sum_{\emptyset \neq X \subseteq \Omega} m(X) \log|X| = \sum_{\emptyset \neq X \subseteq \Omega} m_X \log|X| = \mathbf{i}^T \mathbf{m},$$

d.h. die Komponenten von i^T sind die verschiedenen Werte $\log|X|$.

Die Basis zur Lösung von (6.39) stellt der Simplexalgorithmus dar (siehe [Chvátal, 1983]). Dieser berechnet zunächst eine initiale zulässige Basislösung, die dann schrittweise verbessert wird (vgl. Abschnitt 6.3.1.1), indem eine Basisvariable gegen eine Nichtbasisvariable ausgetauscht wird, so daß man zur nächsten Basislösung gelangt. Dies wird solange wiederholt, bis das Minimum der Zielfunktion (in diesem Fall $-\mathbf{i}^T \mathbf{m}$) erreicht wird.

Die Größe von \mathbf{A} kann wie bei der Lösung von T1 bestimmt werden, wobei im dritten Reduktionsschritt zu beachten ist, daß diejenige Spalte in \mathbf{A} verbleibt, die den größten Koeffizienten in I hat; d.h. diejenige, deren zugehörige Variable der größten Teilmenge von Ω entspricht. Ansonsten kann die optimale Lösung offensichtlich nicht erreicht werden.

Wenn $\mathbf{A} \in \mathbb{R}^{k_1 \times r}$, so existieren $\binom{r}{k_1}$ Möglichkeiten, k_1 linear unabhängige Spalten von \mathbf{A} auszuwählen. Somit ist die Gesamtkomplexität von Phase 2

$$O\left(\binom{r}{k_1} k_1 r\right),$$

da $\binom{r}{k_1}$ Iterationen benötigt werden, von denen jede die gesamte Matrix neu berechnet. Es existieren zwar Algorithmen mit polynomieller Laufzeit für LP, Simplex hat jedoch eine sehr gute Laufzeit für "normale" Fälle.

Anmerkungen:

1. Nach dem Fundamentalsatz der linearen Programmierung 6.3.1 erreicht Phase 2 die optimale Lösung, falls eine solche existiert, indem maximal $k_1 + 1$ von Null verschiedene Werte berechnet werden.
2. Trotz der exponentiellen Laufzeit des T2-Algorithmus im schlechtesten Fall, hält der Simplexalgorithmus oft schon nach etwa $3k_1$ Iterationen, so daß die Zahl der Spalten von \mathbf{A} eine untergeordnete Rolle spielt.
3. Falls das Problem keine Lösung besitzt, zeigt Phase 2 dies bereits nach dem Versuch an, die erste Basislösung zu berechnen, d.h. nach $O(k_1^2 r)$ Schritten. Dies ist identisch zu Phase 2 des T1-Algorithmus.
4. Wenn *degenerierte* Lösungen existieren, d.h. wenn Basisvariablen den Wert Null erhalten, sind leichte Modifikationen notwendig, um die Terminierung des Algorithmus zu garantieren (vgl. [Chvátal, 1983], Kapitel 2).
5. Für Spezialfälle wie lineare Programmierung in konstant vielen Dimensionen (d.h. festes r) existieren effizientere Berechnungsmethoden (vgl. etwa [Chvátal, 1983], Kapitel 7), aber die oben beschriebene Grundidee bleibt dieselbe. Zudem sind diese Algorithmen nur für sehr kleine Werte von r praktikabel, während der Simplexalgorithmus oft sehr schnell terminiert, wie in der zweiten Anmerkung festgestellt wurde.

6. Soll ein anderes Unsicherheitsmaß I' maximiert werden, muß in Phase 1 nur eine Zeile abgeändert werden: Statt $m_l(S_i) := l_i$ muß $m_l(X_{S_i}) := l_i$ eingesetzt werden, wobei X_{S_i} diejenige nichtleere Teilmenge von S_i ist, die den größten Koeffizienten in I' hat. Entsprechend muß in Phase 2 das Kriterium zur Auswahl der verbleibenden Spalten im dritten Reduktionsschritt abgeändert werden.

Beispiel 6.3.3 (Fortsetzung) Der Grad der Nichtspezifität der in Beispiel 6.3.1 berechneten Basiswahrscheinlichkeit m betrug

$$I(m) \approx 0.7625.$$

Versucht man nun, I zu maximieren, so erhält man als Ergebnis von Phase 2 die folgenden Werte:

$$m(X) = \begin{cases} 0.1, & X = \{a, b\} \\ 0.1, & X = \{a, d\} \\ 0.3, & X = \{b, c, d\} \\ 0.2, & X = \{a, b, c, d\} \\ 0, & \text{sonst} \end{cases}$$

Zusammen mit den Werten aus Phase 1 ergibt sich nun

$$I(m) \approx 0.8836.$$

Bei dieser Lösung zeigt sich auch, daß die einzige Menge, die einer ausschließlich aus Einsen bestehenden Spalte entspricht, $\{a, b, c, d\}$ ist, deren Koeffizient $\log 4$ der entsprechenden Variable in der Zielfunktion I der größte ist.

6.3.2 Aktualisierung des Benutzermodells

Bisher wurde meist vorausgesetzt, daß eine Wissensbasis in Form eines quantitativen Benutzermodells gegeben ist, mit deren Hilfe die Bewertung des Hypothesenraumes und die benötigten Gewichte der Beobachtungsregeln zu Beginn eines Beobachtungszyklus initialisiert werden konnten. War diese Information nicht vorhanden, so wurden z.B. entsprechende Heuristiken angewandt (siehe Abschnitt 6.1.3.2), um diese Lücken zu schließen. Die aktuellen Beobachtungen innerhalb eines Zyklus führen dann zur Anpassung der Hypothesenbewertung an die aktuelle Situation. Bisher stand jedoch noch kein Mechanismus zur Verfügung, sowohl die Hypothesenbewertung als auch die Regelgewichte (und gegebenenfalls auch die Regeln selbst) dem *Langzeitverhalten* eines beobachteten Agenten anzupassen. Das bedeutet, daß die Ergebnisse aufeinanderfolgender, unabhängiger Planerkennungszyklen nicht in der Repräsentation der Präferenzen des Agenten berücksichtigt wurden. Dies ist jedoch eine unabdingbare Voraussetzung, wenn das Benutzermodell das tatsächliche Verhalten eines Agenten, das während einen längeren Zeitraumes Schwankungen unterworfen sein kann, widerspiegeln soll.

Dieser Abschnitt stellt zwei Verfahren zur Aktualisierung der initialen Hypothesenbewertung sowie der Beobachtungsregeln dar, die darauf beruhen, die Ergebnisse aktueller Planerkennungszyklen in die gegebenen Werte zu integrieren.

6.3.2.1 Aktualisierung der initialen Hypothesenbewertung

Die initiale Hypothesenbewertung m_0 dient in erster Linie als “Fokussierungshilfe”, d.h. sie wird dazu verwendet, Hypothesen, die häufig auftretende Pläne beschreiben, möglichst schnell und eindeutig zu identifizieren. Hintergrund dafür ist die Tatsache, daß einer Hypothese, die sowohl von der aktuellen Evidenz m_{ev} , als auch von m_0 unterstützt wird (d.h. Fokalelement beider Basiswahrscheinlichkeiten ist), durch die Kombination $m_0 \oplus m_{ev}$ ein noch größerer Vertrauensgrad zugeordnet wird als durch m_{ev} alleine.

An m_0 sind dabei folgende Anforderungen zu stellen.

1. Die Werte von m_0 sollen die (relativen) Häufigkeiten des Auftretens der verschiedenen Pläne im Verhalten des zu beobachtenden Agenten widerspiegeln. Das heißt, die statistischen Daten sollen die Grundlage für die Zuweisung von Vertrauenswerten bilden.
2. Jedes Element des Hypothesenraumes soll zu Beginn eines Beobachtungszyklus *prinzipiell möglich* sein, d.h. es darf keine Hypothese von vornherein verworfen werden. Dies gilt auch für Pläne, die im Laufe der bisherigen Beobachtungen noch nie im Verhalten des Benutzers aufgetreten sind. Die Motivation für diese Forderung wurde in Abschnitt 6.1.2 diskutiert. Formal bedeutet dies, daß für alle Hypothesen $h \in \mathcal{P}_0$ die Bedingung

$$Pl_{m_0}(\{h\}) > 0$$

erfüllt sein muß. Gemäß der Definition der Plausibilität ist damit auch die prinzipielle Erreichbarkeit jeder *mehrelementigen* Hypothesenmenge gesichert.

Das hier vorgestellte Verfahren beruht im wesentlichen darauf, die relativen Häufigkeiten der im Anschluß an eine Reihe von Versuchen oder Beobachtungen identifizierten Situationen in eine Basiswahrscheinlichkeit über dem Hypothesenraum zu übertragen. Dabei wird eine “Situation” eindeutig charakterisiert durch eine Äquivalenzklasse möglicher Welten (vgl. dazu auch [Bacchus *et al.*, 1992]) oder im allgemeinen Fall durch eine Wahrscheinlichkeitsverteilung über diesen Klassen.

Es seien bisher n Beobachtungszyklen durchgeführt worden, die die Ergebnisse $X_i \subseteq \mathcal{P}_0$, $i = 1, \dots, n$, lieferten. Das bedeutet, daß am Ende des i -ten Zyklus die Hypothesenmenge X_i eindeutig identifiziert wurde. Diese Situation wird durch die logische Formel $\mathbf{K}_e X_i$ bzw. auf semantischer Seite durch die epistemische Menge $\mathbf{e}(X_i)$ möglicher Welten beschrieben. Dabei wurde wiederum die Menge X_i mit der entsprechenden logischen Formel identifiziert.

Da mehrere Beobachtungszyklen gleiche Ergebnisse liefern können, wird angenommen, daß insgesamt $l \leq n$ der X_i paarweise voneinander verschieden sind. O.B.d.A. seien dies X_1, \dots, X_l , wobei X_j genau k_j -mal aufgetreten sei (es gilt also $\sum_{j=1}^l k_j = n$).

In dieser Situation ist

$$\begin{aligned} \overline{m}^{(n)} : 2^{\mathcal{P}_0} &\rightarrow [0, 1] \\ X &\mapsto \begin{cases} \frac{k_j}{n}, & X = X_j \\ 0, & \text{sonst} \end{cases} \end{aligned} \quad (6.40)$$

die *relative Häufigkeit* aller Hypothesen während dieser n Beobachtungszyklen.

Anmerkungen:

1. $\overline{m}^{(n)}$ ist eine Basiswahrscheinlichkeit.
2. Wird das Ergebnis des i -ten Zyklus durch eine Basiswahrscheinlichkeit $m_{f,i}$ mit $m_{f,i}(X_i) = 1$ beschrieben, so kann $\overline{m}^{(n)}$ äquivalent dargestellt werden als

$$\overline{m}^{(n)}(X) = \frac{1}{n} \sum_{i=1}^n m_{f,i}(X). \quad (6.41)$$

Während $\overline{m}^{(n)}$ die erste der beiden o.a. Forderungen bzgl. m_0 erfüllt, ist dies für die zweite im Falle $X_1 \cup \dots \cup X_l \neq \mathcal{P}_0$ *nicht* gewährleistet. Für $X \subseteq \mathcal{P}_0$ mit $X \cap X_j = \emptyset$ für $j = 1, \dots, l$ gilt nämlich $Pl_{\overline{m}^{(n)}}(X) = 0$, d.h. alle Hypothesen, die bisher noch nicht aufgetreten sind, werden als unmöglich verworfen.

Im Gegensatz dazu ist der durch die leere Basiswahrscheinlichkeit \tilde{m} (mit $\tilde{m}(\mathcal{P}_0) = 1$ und $\tilde{m}(X) = 0$ für alle echten Teilmengen $X \subseteq \mathcal{P}_0$) induzierte Plausibilitätswert für alle Hypothesen gleich 1. Die grundlegende Idee ist es nun, die entsprechende, durch $\mathbf{K}_e \mathcal{P}_0$ gekennzeichnete Situation der totalen Unwissenheit in die Menge der tatsächlich aus Beobachtungen resultierenden Situationen $\mathbf{K}_e X_i$, $i = 1, \dots, n$, mit aufzunehmen (also etwa $m_{f,0} = \tilde{m}$ in (6.40)).

Definition 6.3.5 (akkumulierte Hypothesenbewertung)

Seien $X_1, \dots, X_l \subseteq \mathcal{P}_0$, wie oben beschrieben, die Ergebnisse von n Beobachtungszyklen, wobei X_i genau k_i -mal auftrat (also $\sum_{j=1}^l k_j = n$), $k_0 \in \mathbb{R}^+$. Dann ist

$$\begin{aligned} m^{(n)} : 2^{\mathcal{P}_0} &\rightarrow [0, 1] \\ X &\mapsto \begin{cases} \frac{k_i}{n + k_0}, & X = X_i \\ \frac{k_0}{n + k_0}, & X = \mathcal{P}_0 \\ 0, & \text{sonst} \end{cases} \end{aligned} \quad (6.42)$$

die *akkumulierte Hypothesenbewertung* nach n Zyklen für den Fall $X_i \neq \mathcal{P}_0$ für alle i . Gilt etwa $X_1 = \mathcal{P}_0$, so ist $m^{(n)}(\mathcal{P}_0) = (k_1 + k_0)/(n + k_0)$.

Anmerkungen:

1. Analog zu (6.40) kann auch hier $m^{(n)}$ dargestellt werden als

$$m^{(n)}(X) = \frac{1}{n + k_0} \left(\sum_{i=1}^n m_{f,i}(X) + k_0 \tilde{m}(X) \right). \quad (6.43)$$

2. Der Gewichtungsfaktor k_0 quantifiziert die relative Stärke des Einflusses sowohl von \tilde{m} als Beschreibung eines Endzustandes als auch der verschiedenen $m_{f,i}$ auf die resultierende Gesamtbewertung:

- Ist $k_0 = 1$, so entspricht dies einer Gleichbehandlung der einzelnen $m_{f,i}$ und des “Korrekturfaktors” \tilde{m} , d.h. \tilde{m} beschreibt lediglich das Resultat des 0-ten Beobachtungszyklus.
- Ist $k_0 > 1$, so wird der Einfluß der jüngsten Zyklen (aus denen die $m_{f,i}$ stammen) auf die Gesamtbewertung abgeschwächt. Dies verhindert eine zu starke Fokussierung nach nur wenigen Beobachtungszyklen (nach nur einem Durchgang ist bei $k_0 = 1$ beispielsweise $m^{(1)}(X_1) = 0.5$).
- Ist $k_0 < 1$, so wird der Einfluß von \tilde{m} auf die Beibehaltung einer positiven Plausibilität aller Hypothesen beschränkt. In diesem Fall werden die durch die $m_{f,i}$ gewonnenen Informationen als sehr zuverlässig betrachtet.

3. $m^{(n)}$ ist eine Basiswahrscheinlichkeit: $m^{(n)}(\emptyset) = 0$, da $m_{f,i}(\emptyset) = 0$ für alle i und $\tilde{m}(\emptyset) = 0$. Zudem gilt

$$\begin{aligned} \sum_{X \subseteq \mathcal{P}_0} m^{(n)}(X) &= \sum_{X \subset \mathcal{P}_0} m^{(n)}(X) + m^{(n)}(\mathcal{P}_0) \\ &= \sum_{i=1}^l m^{(n)}(X_i) + m^{(n)}(\mathcal{P}_0) \\ &= \sum_{i=1}^l \frac{k_i}{n + k_0} + \frac{k_0}{n + k_0} \\ &= \frac{n}{n + k_0} + \frac{k_0}{n + k_0} \\ &= 1 \end{aligned}$$

im Fall $X_i \neq \mathcal{P}_0$ für alle i und entsprechend für den Fall $X_j = \mathcal{P}_0$.

Die akkumulierte Hypothesenbewertung erfüllt die Anforderungen an eine initiale Hypothesenbewertung:

- $Pl_{m^{(n)}}(X) \geq k_0/(n + k_0)$ für alle $\emptyset \neq X \subseteq \mathcal{P}_0$.
- $m^{(n)}$ spiegelt die statistischen Daten über das Langzeitverhalten des beobachteten Agenten wider, denn für alle $X \subset \mathcal{P}_0$ gilt

$$\bar{m}^{(n)}(X) - m^{(n)}(X) \leq \frac{k_0}{n(n + k_0)}$$

In dieser Ungleichung zeigt sich, inwiefern k_0 für die Abweichung von den tatsächlichen relativen Häufigkeiten verantwortlich ist. Die Abweichung für \mathcal{P}_0 selbst ist $k_0/(n + k_0)$.

Aus Definition 6.3.5 und Gleichung (6.43) kann eine Prozedur zur Aktualisierung einer bestehenden initialen Hypothesenbewertung aufgrund zusätzlicher Beobachtungszyklen abgeleitet werden. Seien dazu $m^{(n)}$ wie oben eine akkumulierte Hypothesenbewertung nach n Zyklen, $m_{f,n+1}, \dots, m_{f,n+o}$ die finalen Bewertungen des Hypothesenraums von o weiteren Zyklen. Dabei sei $m_{f,n+i}$ jeweils auf X_{n+i} fokussiert. D.h. X_{n+i} ist die kleinste Teilmenge des Hypothesenraumes, für den $Bel_{m_{f,n+i}}(X_{n+i}) = 1$. Hat $m_{f,n+i}$ mehr als ein Fokalelement, so wird die durch sie repräsentierte Information durch Angabe der Menge aller durch die gegebene Evidenz unterstützten Hypothesen X_{n+i} approximiert. $\bar{m}^{(o)} := \frac{1}{o} \sum_{i=1}^o m_{f,n+i}$ bezeichne den "Durchschnitt" der $m_{f,n+i}$, d.h. die relative Häufigkeit der verschiedenen Hypothesenmengen in den Zyklen $n + 1$ bis $n + o$.

Definition 6.3.6 (gewichtete Aktualisierung)

In dieser Situation ist

$$m^{(n+o)} = m^{(n)} +_{n,o} \bar{m}^{(o)} : 2^{\mathcal{P}_0} \rightarrow [0, 1]$$

$$X \mapsto \frac{n \cdot m^{(n)}(X) + o \cdot \bar{m}^{(o)}(X)}{n + o}$$

die n - o -gewichtete Aktualisierung von $m^{(n)}$ mit $m_{f,n+1}, \dots, m_{f,n+o}$.

Ähnlich wie in Gleichung (6.43) läßt sich $m^{(n+o)}$ darstellen als

$$m^{(n+o)}(X) = \frac{1}{n + o + k_0} \left(\sum_{i=1}^{n+o} m_{f,i}(X) + k_0 \tilde{m}(X) \right), \quad (6.44)$$

so daß auch die obige Abweichung gegenüber der relativen Häufigkeit für den Fall $n + o$ weiterhin gültig ist.

Anmerkung: Während die Berechnung der akkumulierten Hypothesenbewertung sowie der gewichteten Aktualisierung im wesentlichen der Ableitung einer Wahrscheinlichkeit aus den Häufigkeiten des Auftretens bestimmter Ereignisse im Anschluß an

ein Experiment im Sinne der mengenwertigen Statistik entspricht (siehe [Dubois und Prade, 1992]), so können die Berechnungen gemäß Definitionen 6.3.5 und 6.3.6 im Falle *mehrerer* Fokalelemente der finalen Hypothesenbewertungen $m_{f,i}$ nicht mehr auf diese Weise gerechtfertigt werden. Vielmehr steht hier die Durchschnittsbildung aller erzielten Resultate im Vordergrund.

Eine *Situation* als Ergebnis eines Beobachtungszyklus wird in diesem Fall nicht durch eine Äquivalenzklasse möglicher Welten, sondern durch ein Universum mit assoziierter Wahrscheinlichkeit beschrieben. Die Akkumulation und Aktualisierung bestehen dann in einer Vereinigung dieser Universen und der entsprechenden Wahrscheinlichkeiten.

6.3.2.2 Aktualisierung der Beobachtungsregeln

Die Aktualisierung von Beobachtungsregeln soll zunächst am Beispiel *eines* zusätzlichen Zyklus untersucht werden. Die Verallgemeinerung für den Fall mit mehreren solcher Zyklen ist dann sehr einfach. Dabei wird die in Abschnitt 6.1.3.3.1 vorgenommene Typisierung der Regeln gemäß ihrem jeweiligen Verhalten im Falle verletzter Constraints eine grundlegende Rolle spielen. Seien dazu nochmals die beiden Beobachtungsregeln R_1 und R_2 wie in Abbildung 6.17 gegeben. Grundsätzlich müssen zwei




Abbildung 6.17: Die Beobachtungsregeln R_1 und R_2 .

Arten von Regelaktualisierungen betrachtet werden. Die erste bezieht sich im wesentlichen auf die Regelgewichte, d.h. im Laufe weiterer Beobachtungszyklen wird die *Struktur* der Regeln beibehalten, während die assoziierten numerischen Werte an die tatsächlichen Gegebenheiten angepaßt werden. Die zweite erlaubt darüberhinaus auch eine Veränderung der Regelstruktur, indem etwa zusätzliche Klauseln aufgenommen werden. Zunächst soll jedoch der erste Fall untersucht werden.

Die Darstellung von R_1 und R_2 in Abbildung 6.17 entspreche deren Status nach n Beobachtungszyklen. Im $(n + 1)$ -ten Zyklus werde R_1 (R_2) angewandt und o.B.d.A. Hypothese H_1 identifiziert (es gelte dabei $H_1 \in G_{\Delta}(A_1)$). Dann werden die entspre-

chenden Regelgewichte für R_1 und R_2 wie folgt aktualisiert:

$$\begin{array}{rcl}
 A_1 & \begin{array}{l} \nearrow \\ \searrow \end{array} & \begin{array}{l} \bigcup_{H \in G_{\Delta}(A_1)} M(H) \left\langle \frac{n \cdot c_0 + 1}{n + 1} \right\rangle \\ \mathcal{P}_0 \left\langle 1 - \frac{n \cdot c_0 + 1}{n + 1} \right\rangle \end{array} \\
 \\
 A_2 & \begin{array}{l} \nearrow \\ \rightarrow \\ \rightarrow \\ \searrow \\ \searrow \end{array} & \begin{array}{l} H_1 \left\langle \frac{n \cdot v_1 + 1}{n + 1} \right\rangle \\ H_2 \left\langle \frac{n \cdot v_2}{n + 1} \right\rangle \\ \vdots \\ H_n \left\langle \frac{n \cdot v_n}{n + 1} \right\rangle \\ \mathcal{P}_0 \left\langle \frac{n \cdot v_{\mathcal{P}_0}}{n + 1} \right\rangle \end{array} \quad (6.45)
 \end{array}$$

Das heißt, die relative Häufigkeit des Auftretens von H_1 während der $n + 1$ Regelanwendungen wurde um $1/(n + 1)$ erhöht (im Falle von R_1 wurde dies als erneute Bestätigung der ersten Klausel interpretiert). Dies ist in Übereinstimmung mit der Interpretation der Regelgewichte als bedingten Wahrscheinlichkeiten (siehe Abschnitt 6.1.3.2) und der Ableitung von Wahrscheinlichkeiten aus relativen Häufigkeiten (siehe Abschnitt 6.3.2.1).

Im positiven Fall der Bestätigung einer Regel ist somit die Aktualisierung für alle in Tabelle 6.1 aufgeführten Regeltypen gleich, Unterschiede treten erst im “negativen” Fall, d.h. der Anwendung einer Regel, ohne daß eine ihrer Konklusionen bestätigt wird, auf.

Sei also wieder die gleiche Situation wie oben gegeben, jedoch werde im $(n + 1)$ -ten Zyklus die Hypothese $\hat{H} \notin G_{\Delta}(A_1), G_{\Delta}(A_2)$ bestätigt. Dies wird wie im Falle der Konfliktauflösung bei verletzten Constraints (siehe Abschnitt 6.1.3.3) im Falle der als $\times D$ klassifizierten Regeln als partielle Unwissenheit (dies gilt standardmäßig auch für die $\times S$ -Regeln), im Falle der “Bayes’schen” Regeln $\times B$ als Evidenz gegen die Konklusionen der Regel gewertet. Dementsprechend ergeben sich die Aktualisierungen

$$\begin{array}{rcl}
 A_2 & \begin{array}{l} \nearrow \\ \rightarrow \\ \rightarrow \end{array} & \begin{array}{l} H_1 \left\langle \frac{n \cdot v_1}{n + 1} \right\rangle \\ \vdots \\ H_n \left\langle \frac{n \cdot v_n}{n + 1} \right\rangle \\ \mathcal{P}_0 \left\langle \frac{n \cdot v_{\mathcal{P}_0} + 1}{n + 1} \right\rangle \end{array} \quad (6.46)
 \end{array}$$

für R_2 und entsprechend für R_1 im Falle der Typen $\times D$ und $\times S$ sowie

$$\begin{array}{r}
 A_2 \begin{array}{l} \nearrow \\ \searrow \\ \searrow \end{array} \begin{array}{l} H_1 \left\langle \frac{n \cdot v_1}{n+1} \right\rangle \\ \vdots \\ H_n \left\langle \frac{n \cdot v_n}{n+1} \right\rangle \\ \hline \bigcup_{H \in G_\Delta(A_2)} M(H) \left\langle \frac{1}{n+1} \right\rangle \end{array} \quad (6.47)
 \end{array}$$

für die Fälle $\times B$.

Anmerkung: Wie bei der Typisierung von Beobachtungsregeln in Abschnitt 6.1.3.3.1 bzgl. ihres Verhaltens im Konfliktfall, so muß auch hier \mathcal{P}_0 gegebenenfalls durch die Menge \mathcal{P}_{A_i} aller A_i nicht explizit ausschließenden Pläne ersetzt werden.

Die in (6.45), (6.46) und (6.47) beschriebenen Aktualisierungen orientierten sich einerseits an den verschiedenen Strategien zur Konfliktauflösung im Falle verletzter Constraints, andererseits an dem im vorigen Abschnitt beschriebenen Aktualisierungsverfahren für initiale Hypothesenbewertungen aufgrund zusätzlicher Beobachtungszyklen. Betrachtet man die den Regelgewichten entsprechenden Basiswahrscheinlichkeiten, so lassen sich die wesentlichen Aspekte der Regelaktualisierung ähnlich wie in Definition 6.3.6 darstellen. Die Identifikation der aktualisierten Regelgewichte mit bedingten Wahrscheinlichkeiten erfolgt wiederum über eine frequentistische Interpretation der vorhandenen (statistischen) Daten über das Verhalten des Agenten, die die Grundlage für die Zuweisung von Vertrauenswerten bildet.

Zusätzlich zu den bisher angegebenen Aktualisierungen für Beobachtungsregeln ist es möglich, die neu gewonnene Information zur *Verfeinerung* der Regeln zu verwenden.⁸ Dies ist dann möglich, wenn die im $(n+1)$ -ten Zyklus identifizierte Hypothese \hat{H} Teilmenge eines der H_i ist. In diesem Fall kann die Aktualisierung entweder wie bisher erfolgen, oder es wird eine neue Klausel in die Regel eingeführt, die die Konklusion \hat{H} als Spezialfall der entsprechenden Hypothese H_i berücksichtigt und zu folgender

⁸Diese Operation dient in erster Linie zur Anpassung einer gemäß (6.3) initialisierten Regel an das tatsächliche Benutzerverhalten. Gleichzeitig kann sie als inverse Operation zur Vergrößerung von Regeln betrachtet werden (siehe dazu die Anmerkungen im Zusammenhang mit der Regelmotifikation (6.18)). Prinzipiell wäre auch die Induktion *allgemeinerer* Regeln mit unspezifischeren Hypothesen möglich. Dabei käme es einerseits zu einem Informationsverlust, andererseits wäre die "Entwicklung" der Regeln über einen längeren Beobachtungszeitraum vereinzelter Abweichungen vom Standardverhalten gegenüber weniger anfällig. Der tatsächliche Nutzen einer solchen Operation müßte unter Berücksichtigung der Variationsmöglichkeiten und der Notwendigkeit der *genauen* Identifizierung des aktuellen Planes in einer Domäne untersucht werden.

Aktualisierung führt:

$$\begin{array}{rcl}
 & & H_1 \left\langle \frac{n \cdot v_1}{n+1} \right\rangle \\
 & \nearrow & \vdots \\
 A_2 & & H_n \left\langle \frac{n \cdot v_n}{n+1} \right\rangle \\
 & \searrow & \hat{H} \left\langle \frac{1}{n+1} \right\rangle \\
 & \searrow & \mathcal{P}_0 \left\langle \frac{n \cdot v_{\mathcal{P}_0}}{n+1} \right\rangle
 \end{array} \tag{6.48}$$

Dieses Verfahren ist insbesondere für Regeln der Typen $I \times$ wichtig, die lediglich aufgrund der strukturellen Information aus der Planhierarchie gebildet wurden und dadurch schrittweise verfeinert werden können. Ein Nachteil dieses Verfahrens ist, daß die Anzahl der Konklusionen der Regeln und somit der Fokalelemente der zur Berechnung der induzierten Hypothesenstärke \tilde{r} gemäß Definition 6.1.11 sowie von \tilde{r} selbst ansteigt und somit die Komplexität der Berechnungen erhöht wird. Somit sollte es nicht auf approximierte Regeln vom Typ AD angewandt werden. Wächst die Anzahl der Konklusionen einer Regel zu stark, so können die in Abschnitt 6.5.2 beschriebenen Approximationsalgorithmen angewandt werden.

Somit kann eine Regel nun vollständig charakterisiert werden durch die Angabe des Typs der Konfliktauflösung bei verletzten Constraints und die Kennzeichnung, ob im Falle von Aktualisierungen Verfeinerungen gemäß (6.48) zulässig sind (+) oder nicht (-). Entsprechende Angaben sind z.B. ID^+ oder AD^- .

Anmerkung: Regeln vom Typ $\times \times^-$, die aufgrund zusätzlicher Information *nicht* verfeinert werden, können somit nicht mehr als Konditionale der Form

$$\mathbf{K}_e H \mid \mathbf{K}_{\mathcal{C}(\Theta)} A, \mathbf{K} C_H(A)$$

dargestellt werden. Vielmehr entsprechen sie Mengen von Ausdrücken

$$\mathbf{K}_{\mathcal{C}(\mathcal{P}_0)} H \mid \mathbf{K}_{\mathcal{C}(\Theta)} A, \mathbf{K} C_H(A),$$

wobei $\mathcal{C}(\mathcal{P}_0)$ die kleinste Δ -Partitionierung von \mathcal{P}_0 ist, die $G_\Delta(A)$ umfaßt (siehe dazu Definition 6.1.4). Die aktualisierten Regelgewichte gemäß der obigen Diskussion entsprechen nämlich exakt der durch die Regelgewichte im $\times \times^+$ -Fall und $\mathcal{C}(\mathcal{P}_0)$ induzierten Basiswahrscheinlichkeit gemäß Definition 6.1.6.

6.4 Spezielle Aspekte der Planerkennung

Dieser Abschnitt diskutiert kurz einige besondere Aspekte der Planerkennung und ihre Behandlung im hier vorgestellten Ansatz. Es handelt sich dabei um die Erkennung

überlappender und verzahnter Pläne, die Behandlung zusätzlicher Information in der Beschreibung von Plänen und die prinzipielle Annahme der Vollständigkeit der zur Verfügung stehenden Planhierarchie.

6.4.1 Überlappende und verzahnte Pläne

Zwei Spezialfälle in der Planerkennung, die die grundlegende Annahme eines einzigen Benutzerplans verletzen, betreffen die *überlappende* und *verzahnte* Ausführung zweier oder mehrerer Pläne. Dieser Abschnitt untersucht die Anwendbarkeit der bisher vorgestellten Konzepte auf diese Fälle, wobei folgendes zu berücksichtigen ist.

Ziel der Verwendung eines Formalismus wie Dempster-Shafer Theorie oder Wahrscheinlichkeitstheorie ist die Identifizierung *eines* Elementes des Hypothesenraumes als die wahre Beschreibung des aktuellen Weltzustandes.⁹ Angewandt auf die Planerkennung bedeutet dies, daß davon ausgegangen wird, daß der beobachtete Agent zu jedem Zeitpunkt *genau einen Plan* verfolgt. Daher ist es zur Erkennung mehrerer simultaner Pläne, die überlappend oder verzahnt ausgeführt werden, notwendig, daß der Planerkenner, der die hier vorgestellten Konzepte zur Bewertung seiner Hypothesen verwendet, gegebenenfalls mehrere “Kopien” des Hypothesenraumes unterhält und diese unabhängig voneinander bewerten läßt. Insofern ist hier lediglich sicherzustellen, daß bei der Bewertung von Plänen, die prinzipiell im gleichen Zeitintervall auftreten können, alle Alternativen weiterhin gültig bleiben, d.h. zumindest einen Plausibilitätswert > 0 erhalten.

Seien dazu H_1, H_2 Pläne mit gültigen Aktionssequenzen a_1, \dots, a_n bzw. b_1, \dots, b_m (d.h. eine Ausführung der Aktionen in dieser Reihenfolge erfüllt alle Constraints). Eine *Überlappung* beider Pläne ergibt sich in in folgender Situation:

$$\begin{array}{cccccccc} a_1 & a_2 & \dots & a_{n-k+1} & \dots & a_n & & \\ & & & b_1 & \dots & b_k & b_{k+1} & \dots & b_m \\ \hline & & & & & & & & & > t \end{array}$$

Dabei gilt $a_{n-k+i} = b_i$ für $1 \leq i \leq k$. Diese Aktionen, die sowohl zur “Funktionalität” von H_1 als auch von H_2 beitragen, müssen lediglich einmal ausgeführt werden. Aus der Sicht des Planerkenners ist es dabei erforderlich, während der letzten k Aktionen von H_1 auch H_2 als möglichen Benutzerplan zu identifizieren.

Während der Planerkennung müssen hier zwei Fälle unterschieden werden:

1. a_i mit $i \geq k + n - 1$ wird beobachtet
2. a_i mit $i < k + n - 1$ wird beobachtet

⁹Zwar kann die Dempster-Shafer Theorie auch mehrelementige Mengen von Hypothesen direkt bewerten, doch entsprechen diese der (exklusiven) Disjunktion ihrer Elemente.

zu 1.: In diesem Fall ist die beobachtete Aktion sowohl in der Dekomposition von H_1 als auch in der von H_2 enthalten. Gemäß den Ausführungen in Abschnitt 6.1.3.2 zur Initialisierung von Beobachtungsregeln treten somit auch beide Pläne als Konklusionen der zu a_i gehörenden Regel auf. Das in Abschnitt 6.3.2.2 angegebene Verfahren zur Aktualisierung der Regeln ändert dies nicht. Die Beobachtung unterstützt somit beide Hypothesen.

zu 2.: Wird beispielsweise a_1 beobachtet und ist diese Aktion in Plan H_2 explizit ausgeschlossen, so wird H_2 durch diese Beobachtung als Hypothese bereits verworfen. Dies bedeutet, daß während der Abarbeitung von H_1 eine Überlappung mit H_2 nicht mehr festgestellt werden kann. Während negative Aussagen bzgl. des Auftretens bestimmter Aktionen nur sehr selten in Plandekompositionen auftreten und daher bei Beobachtungsregeln, die gemäß (6.3) initialisiert wurden, nur in Ausnahmefällen zu diesem Problem führen, muß dieser Aspekt bei “manueller” Eingabe auf jeden Fall berücksichtigt werden (siehe zu diesem Aspekt auch die Behandlung von “Cancel-Aktionen” in Abschnitt 6.4.2).

Bei der *verzahnten* Ausführung von H_1 und H_2 ergibt sich eine Aktionsfolge

$$x_1 \ x_2 \ \dots \ x_l \quad \text{mit } l \leq n + m,$$

wobei jedes x_i einem a_j oder b_j entspricht. D.h. in diesem Fall werden die zu H_1 und H_2 gehörenden Aktionen “gemischt”, soweit dies die jeweiligen Constraints zulassen. Sei o.B.d.A. die erste Aktion $x_1 = a_j$ für ein $j \leq n$. Aus der Sicht des Planerkennters müssen dann spätestens nach dem Auftreten der ersten zu H_2 gehörenden Aktion b_i beide Pläne als gültige Hypothesen erkannt werden.

Anmerkungen:

1. Die Ungleichung $l \leq n + m$ ergibt sich, weil manche der a_i und b_j identisch sein können und somit u.U. nur einmal ausgeführt werden.
2. Es wird angenommen, daß außer den in den Dekompositionen von H_1 und H_2 explizit angegebenen Aktionen keine weiteren mehr ausgeführt werden. Die Tatsache, daß Aktionen auch während der Ausführung von Plänen auftreten können, die diese nicht in ihrer Dekomposition enthalten, wurde bereits mehrfach diskutiert. Die Initialisierung der Beobachtungsregeln und der Aktualisierungsmechanismus garantieren hier die gewünschten Ergebnisse (siehe Abschnitte 6.1.3.2 und 6.3.2.2).

Hier muß ähnlich wie im Fall überlappender Pläne die “Verträglichkeit” von H_1 und H_2 miteinander sichergestellt sein in dem Sinne, daß ein Vorkommen einer Aktion a_i (b_i) nicht den Plan H_2 (H_1) als Hypothese verwirft.

6.4.2 Weitere Modellierungsaspekte

Bisher wurde meist davon ausgegangen, daß ein Plan durch Angabe einer Menge zu seiner Ausführung notwendiger Aktionen sowie temporalen und strukturellen Cons-

traints zwischen diesen beschrieben wird. Es kann jedoch nützlich sein, zusätzliches, in der Regel domänenabhängiges Wissen bei der Modellierung von Aktionen und Plänen zu verwenden.

Vor allem informationsbeschaffende Aktionen wie das `ls` Kommando in Unix oder `header` in email, die den Zustand der Welt nicht verändern, sondern lediglich Daten über den aktuellen Systemzustand liefern, werden sehr oft von einem Agenten in seine Aktionssequenzen eingestreut. Da solche Aktionen nicht direkt zum Erreichen eines Domänenziels eingesetzt werden können, dienen sie typischerweise dazu, den Erfolg einer anderen Aktion zu überprüfen oder sich nochmals gewisser Details zu vergewissern.

Aufgrund dieser fehlenden Beziehung zu den Zielen eines Agenten liefert die Beobachtung einer solchen Aktion keinerlei Hinweis auf den tatsächlich verfolgten Plan. Anstelle der Initialisierung einer Beobachtungsregel gemäß (6.3) ist es daher sinnvoll, einer solchen Aktion eine "leere" Regel zuzuordnen (siehe (6.4)) und diese *nicht* weiter zu aktualisieren.

Wie bereits in Abschnitt 6.1.3 mehrfach erwähnt, kann neben der in der Dekompositionshierarchie enthaltenen positiven Information bzgl. des Auftretens von Aktionen innerhalb gewisser Pläne auch *negative* Information vorhanden sein, die Aussagen darüber enthält, daß ein Plan das Vorkommen einer Aktion explizit ausschließt. In [Thies, 1994] wird eine solche Aktion als *Cancel-Aktion* bezeichnet.

Bei der Beobachtungsregel einer Aktion a , die ausschließlich während der Ausführung von Plänen in einer Menge $P_a \subseteq \mathcal{P}_0$ vorkommen dürfen, ist darauf zu achten, daß die mit a assoziierte Regelstärke s_a die Plausibilität aller anderen Pläne auf Null setzt, d.h. $Pl_{s_a}(H) = 0$ für $H \notin P_a$.

Weiterhin kann die Beschreibung eines Planes beispielsweise Information über die maximale Länge einer entsprechenden Aktionssequenz oder den maximalen zeitlichen Abstand zweier Aktionen enthalten. Diese Art von Information muß als Constraint in die Modellierung eines Planes aufgenommen werden und unterliegt somit der Überwachung durch den Planerkenner, der die Information bzgl. ihrer Erfüllung zur Revision der Regelstärke liefert (siehe auch Abschnitt 6.1.3.3).

6.4.3 Die Vollständigkeitsannahme

Eine der prinzipiellen Annahmen, die den meisten Planerkennungsansätzen zugrundeliegt, bezieht sich auf die Vollständigkeit des zur Verfügung stehenden Wissens über Pläne. Diese bezieht sich sowohl auf die Menge der Pläne in der gegebenen Planbibliothek, als auch auf deren Dekompositionen in einzelne Aktionen. In [Kautz und Allen, 1986] wird diese "Vollständigkeit der Abstraktions- und Dekompositionshierarchie" mittels Circumscription hergestellt und formalisiert. Sie besagt im wesentlichen, daß

- es keine anderen Pläne gibt außer den explizit aufgeführten und
- es keine weiteren Alternativen zur Ausführung dieser Pläne gibt als die explizit angegebenen Dekompositionen.

Diese beiden Annahmen finden sich in ähnlicher Form ebenso im hier vorgestellten numerischen Ansatz wieder. Die *Closed-World Assumption* bzgl. der Menge der angegebenen Pläne zeigt sich darin, daß jede Hypothesenbewertung als Basiswahrscheinlichkeit m über dem Hypothesenraum dargestellt wird, die definitionsgemäß die Bedingung

$$\sum_{X \subseteq \mathcal{P}_0} m(X) = 1 \quad (6.49)$$

erfüllt. Der Vollständigkeit der Dekompositionen entspricht hier die Vollständigkeit der “ist Teilschritt”-Relation. D.h. die Beobachtungsregeln repräsentieren implizit die Annahme, daß die verschiedenen Aktionen ausschließlich in den in den Konklusionen enthaltenen Plänen auftreten können (da die Regelgewichte wiederum eine Basiswahrscheinlichkeit bilden). Umgekehrt bedeutet dies, daß eine Aktion, die nicht explizit in der Dekomposition eines Planes aufgeführt ist, diesen auch nicht als Evidenz direkt unterstützt. Einzige Ausnahme dazu ist die Einführung einer Klausel zur expliziten Repräsentation partieller Unwissenheit in die Beobachtungsregeln (siehe (6.2) und (6.3)).

Zur Lockerung dieser Annahmen wird in [Carberry, 1990a] explizit eine zusätzliche Hypothese *Other* eingeführt, die einen weiteren, unbekanntem Plan repräsentiert. Um der potentiellen Unvollständigkeit der Planbibliothek Rechnung zu tragen, weisen die Präferenzregeln dieser Hypothese jeweils einen bestimmten positiven numerischen Wert zu. Nimmt die Bewertung dieser Hypothese einen hohen Wert an, so wird dies als Zeichen für das Auftreten eines “neuen” Planes (sog. *novel plan*) oder eine fehlerhafte Ausführung eines bekannten Planes interpretiert.

Eine weitere Möglichkeit zur Lockerung der Vollständigkeitsannahme ist die Verwendung einer nicht normierten Version der Dempster-Shafer Theorie, insbesondere von Dempsters Regel. In diesem Fall würde die Forderung (6.49) aus der Definition der Basiswahrscheinlichkeiten entfernt werden. Eine Untersuchung der Konsequenzen dieses Vorgehens findet sich in [Heinsohn, 1986]. Es zeigte sich, daß selbst bei geringfügigen Konflikten der miteinander zu kombinierenden Basiswahrscheinlichkeiten der der leeren Menge zugewiesene numerische Wert sehr schnell anwächst und nie mehr kleiner wird, da diese keine echten Teilmengen besitzt, auf die $m(\emptyset)$ verteilt werden könnte.

6.5 Komplexitätsbetrachtungen

Dieser Abschnitt beschäftigt sich mit Möglichkeiten zur Reduzierung der Komplexität der zur Verarbeitung von Beobachtungen und zur Bewertung von Planhypothesen notwendigen Berechnungen. Neben einer kurzen Auflistung der in den vorhergehenden Abschnitten bereits angesprochenen Methoden bildet die Untersuchung von Verfahren zur Verringerung der Anzahl der Fokalelemente von Basiswahrscheinlichkeiten den Schwerpunkt dieser Betrachtungen.

6.5.1 Berechnung der Hypothesenstärke

Die Hauptfaktoren, die die Komplexität der Berechnung der Hypothesenstärke gemäß Definition 6.1.8 beeinflussen, sind die Anzahl der Summanden, d.h. die Anzahl der aktuell angewandten Beobachtungsregeln, sowie der direkt unterstützten Hypothesen, die von der Anzahl der “rechten Seiten” dieser Regeln abhängen.

Die Anzahl der anzuwendenden Beobachtungsregeln konnte durch die Einführung der Δ -Partitionierungen des Evidenzenraumes begrenzt werden. Dies wurde in Abschnitt 6.1.3.2.2 beschrieben. Dabei wurden mögliche Beobachtungen mit äquivalentem Verhalten (bzgl. ihrer Auswirkungen auf den Hypothesenraum) so zusammengefaßt, daß zu jeder Äquivalenzklasse nur noch eine Beobachtungsregel gehört. Auf der logischen Seite spiegelte sich dies in der Einführung des abgeleiteten Modaloperators \mathbf{K}_C und der Darstellung der Beobachtungsregeln als Konditionale der Form $\mathbf{K}_e H | \mathbf{K}_C A$ wider. Die Anzahl der Summanden in der Berechnung der (revidierten) Hypothesenstärke ist dabei die Mächtigkeit $|\mathcal{C}|$ der aktuellen Δ -Partitionierung.

Die Anzahl der Hypothesen, die durch die aktuelle Evidenz direkt unterstützt werden, für die die Hypothesenstärke also überhaupt berechnet werden muß (alle anderen erhalten den Wert 0) ist abhängig von der Größe der mit den einzelnen Teilmengen des Evidenzenraumes assoziierten Hypothesenmengen (siehe Anmerkung zu Definition 5.2.1). Hier besteht die Möglichkeit, Beobachtungsregeln zu approximieren, wie dies bereits in Abschnitt 6.1.3.3 angedeutet wurde, indem alle mit einer bestimmten Teilmenge des Evidenzenraumes assoziierten Hypothesen zusammengefaßt werden, so daß jede Beobachtungsregel maximal zwei rechte Seiten erhält. Der hierbei in Kauf zu nehmende Informationsverlust ist umso größer, je stärker die einzelnen Gewichte in der ursprünglichen Regel voneinander abweichen und je weniger Elemente die ursprünglichen Hypothesenmengen gemeinsam haben.

6.5.2 Approximative Berechnungen in der DST

Einer der wesentlichen Kritikpunkte an der Dempster-Shafer Theorie ist die Komplexität der notwendigen Berechnungen, insbesondere der Kombination zweier Basiswahrscheinlichkeiten mit Dempsters Regel. [Orponen, 1990] enthält den Beweis, daß diese keinen Algorithmus mit polynomieller Laufzeit besitzt. Hauptverantwortlich dafür ist die exponentielle Größe der zugrundeliegenden Ereignisräume.

Im folgenden werden zunächst Kriterien zur Beurteilung der Qualität einer Approximation sowie verschiedene Algorithmen aus der Literatur vorgestellt und der neue Algorithmus D1 beschrieben, bevor eine empirische Untersuchung und die dabei erzielten Ergebnisse diskutiert werden. Eine Zusammenfassung dieser Untersuchung findet sich in [Bauer, 1996b].

6.5.2.1 Fehlermaße und Approximationsalgorithmen

Eine prinzipielle Möglichkeit zur Reduzierung der Komplexität ist eine Beschränkung der Anzahl der Fokalelemente der beteiligten Funktionen. Dies läßt sich i.a. nur durch Approximationen der Eingaben realisieren. Eine bereits in einer Erweiterung von MYCIN [Gordon und Shortliffe, 1985] verwendete Methode beruht darauf, den Ereignisraum auf diejenigen Hypothesenmengen einzuschränken, die explizit als mögliche Diagnosen aufgeführt sind, und diese in einer strikten Hierarchie in Form eines Baumes anzuordnen. Die Motivation dafür ist die Beobachtung, daß ausschließlich diese Hypothesen eine "natürliche Interpretation" besitzen. Ein Problem dieser Methode ist die Verletzung der fundamentalen Gleichung

$$Bel(X) = 1 - Pl(\bar{X}),$$

falls nicht sowohl X , als auch das Komplement \bar{X} zur Menge dieser explizit "erlaubten" Hypothesen zählen. Diese Methode wird weiter unten im Zusammenhang mit speziellen Fehlermaßen nochmals aufgegriffen.

Andere Approximationen zielen darauf ab, die Anzahl der Fokalelemente einer gegebenen Basiswahrscheinlichkeit durch Zusammenfassen oder Streichen niedrig bewerteter Ereignisse zu reduzieren. Die Struktur des Ereignisraumes bleibt unverändert, so daß das o.a. Problem hier nicht auftritt. Um verschiedene Approximationen miteinander vergleichen zu können, ist die Definition verschiedener Fehlermaße notwendig, die die jeweilige Abweichung vom tatsächlichen Wert quantifizieren. Im folgenden werden zunächst verschiedene solcher Maße eingeführt, bevor einige Approximationen vorgestellt und bzgl. dieser Maße evaluiert werden.

In [Tessem, 1993] wird ein auf der *pignistischen Wahrscheinlichkeit* P_0 beruhendes Fehlermaß verwendet (vergleiche dazu die Definition von Auswahlkriterien in Abschnitt 6.2.2.1). Für diese gilt

$$P_0(\{x\}) = \sum_{A: x \in A \subseteq \Omega} \frac{m(A)}{|A|}.$$

Siehe dazu auch Definition 6.2.4. Ist P_{app} die durch die Approximation m_{app} einer Basiswahrscheinlichkeit m induzierte pignistische Wahrscheinlichkeit, so wird dort als Fehlermaß die Funktion

$$\text{Error1}(m_{app}) = \max_{A \subseteq \Omega} |P_0(A) - P_{app}(A)| \quad (6.50)$$

verwendet. Sollen die vorhandenen numerischen Werte jedoch zur Entscheidungsfindung verwendet werden – weshalb überhaupt P_0 zur Definition des Fehlermaßes herangezogen wurde, so sind u.U. andere Maße sinnvoller, die die *Qualität* der getroffenen Entscheidungen berücksichtigen. Dies führt zur Einführung der folgenden Maße:

Definition 6.5.1 (Fehlermaße)

Seien $x_0, x_1 \in \Omega$ gegeben durch

$$P_0(\{x_0\}) = \max_{x \in \Omega} P_0(\{x\}), \quad P_{app}(\{x_1\}) = \max_{x \in \Omega} P_{app}(\{x\}),$$

d.h. x_0 (x_1) ist die am besten bewertete Hypothese bzgl. der tatsächlichen (approximierten) Werte. Dies induziert die beiden Fehlermaße

$$\text{Error2}(m_{app}) = |\{x \mid P_{app}(\{x\}) > P_{app}(\{x_0\})\}|$$

$$\text{Error3}(m_{app}) = |\{x \mid P_0(\{x\}) > P_0(\{x_1\})\}|.$$

Während Error3 angibt, an welcher Stelle x_1 in der “tatsächlichen Rangfolge” der Ereignisse gestanden hätte – wie gut also die Entscheidung auf der Basis der approximierten Werte ist –, zeigt Error2 an, an wievielter Stelle der Rangfolge die eigentlich beste Wahl x_0 nach der Approximation steht. Während diese beiden Maße – vor allem Error3 – den *qualitativen* Aspekt der Entscheidungsfindung berücksichtigen, bewertet Error1 die *quantitative* Grundlage einer solchen Entscheidung. Bei letzterem wird eine Approximation, die x_1 – und somit die “richtige” Entscheidung – zu stark unterstützt, schlechter bewertet als eine, die nur geringe numerische Abweichungen induziert, x_0 jedoch im Vergleich zu den anderen Ereignissen relativ schlecht bewertet und somit zu einer falschen Entscheidung führt.

Die in [Voorbraak, 1989] vorgestellte *Bayessche Approximation* reduziert eine gegebene Basiswahrscheinlichkeit auf eine diskrete Wahrscheinlichkeit, d.h. die Fokalelemente sind genau die einelementigen Teilmengen des Ereignisraumes.

Definition 6.5.2 (Bayessche Approximation)

Sei m eine Basiswahrscheinlichkeit. Die *Bayessche Approximation* \underline{m} von m ist definiert als

$$\underline{m}(A) = \begin{cases} \frac{\sum_{B:A \subseteq B} m(B)}{\sum_{C \subseteq \Omega} m(C) \cdot |C|}, & |A| = 1 \\ 0, & \text{sonst} \end{cases}$$

Diese Approximation besitzt die folgenden Eigenschaften:

1. $\underline{m}_1 \oplus \underline{m}_2 = \underline{m_1 \oplus m_2}$.
2. Ist m_1 eine Bayessche bpa (d.h. sind alle Fokalelemente von m_1 einelementig), so gilt $\underline{m_1 \oplus m_2} = \underline{m}_1 \oplus \underline{m}_2$.
3. Die Approximation einer Basiswahrscheinlichkeit mit n Fokalelementen kann in Laufzeit $O(n \cdot |\Omega|)$ berechnet werden.

```

begin  $k$ - $l$ - $x$ -Approximation( $m, k, l, x$ )
  sortiere die Teilmengen von  $\Omega$  bzgl. ihres  $m$ -Wertes
   $totalmass := 0$     % bisherige Gesamtmasse der Approximation
   $f := 0$            % bisherige Anzahl der Fokalelemente
  while noch Fokalelemente in  $m$  vorhanden and
    ( $f \leq l$ ) and
    (( $f < k$ ) or ( $totalmass < 1 - x$ ))
    do nimm nächstes Fokalelement  $F$  von  $m$  zur Approximation
       $f := f + 1$ 
       $totalmass := totalmass + m(F)$ 
    od
  Approximation normalisieren
end

```

Abbildung 6.18: Der k - l - x -Approximationsalgorithmus.

Beispiel 6.5.1 Gegeben sei eine Basiswahrscheinlichkeit m über $\Omega = \{a, b, c, d, e\}$ mit folgenden Werten:

$$m(X) = \begin{cases} 0.5, & X = \{a, b\} \\ 0.3, & X = \{a, c, d\} \\ 0.1, & X = \{c\} \\ 0.05, & X = \{c, d\} \\ 0.05, & X = \{d, e\} \\ 0, & \text{sonst} \end{cases} \quad (6.51)$$

Als Bayessche Approximation \underline{m} ergibt sich dann

$$\underline{m}(X) \approx \begin{cases} 0.36, & X = \{a\} \\ 0.23, & X = \{b\} \\ 0.205, & X = \{c\} \\ 0.18, & X = \{d\} \\ 0.023, & X = \{e\} \\ 0, & \text{sonst} \end{cases}$$

Eine weitere, sehr einfache Approximationsmethode wird in [Tessem, 1993] vorgeschlagen. Gegeben seien eine minimale Anzahl k und eine maximale Anzahl l von Fokalelementen, die die Approximation enthalten soll, sowie eine reelle Zahl $x \in [0, 1[$,

die die maximale Größe der zu löschenden Masse bestimmt. Zur Approximation werden nun solange die am höchsten bewerteten Fokalelemente von m hinzugenommen, wie die unteren und oberen Schranken k und l nicht unter- bzw. überschritten werden und die akkumulierte Masse $1 - x$ nicht überschreitet. Anschließend werden die so erhaltenen Werte normalisiert, d.h. mit einem entsprechenden Faktor multipliziert, so daß diese sich wieder zu 1 aufaddieren. Der genaue Algorithmus ist in Abbildung 6.18 dargestellt.

Diese Methode weist folgende Eigenschaften auf:

1. Die Reihenfolge, in der verschiedene Basiswahrscheinlichkeiten miteinander kombiniert werden, beeinflusst das Endergebnis, wenn diese Approximation angewandt wird.
2. Die Laufzeit dieses Algorithmus ist $O(n \cdot \log n)$, wenn m genau n Fokalelemente besitzt.

Beispiel 6.5.2 Sei wiederum die Basiswahrscheinlichkeit m aus (6.51) gegeben. Mit den Werten $k = 2$, $l = 3$ und $x = 0.1$ ergibt sich als Approximation eine Basiswahrscheinlichkeit m' mit

$$m'(X) = \begin{cases} 0.\bar{5}, & X = \{a, b\} \\ 0.\bar{3}, & X = \{a, c, d\} \\ 0.\bar{1}, & X = \{c\} \\ 0, & \text{sonst} \end{cases}$$

Die Methode aus [Lowrance *et al.*, 1986] beruht darauf, die am schlechtesten bewerteten Fokalelemente zu einem zusammenzufassen und diesem die Summe aller m -Werte zuzuweisen.

Definition 6.5.3 (Zusammenfassung, “Summarization”)

Seien m eine Basiswahrscheinlichkeit, k die Anzahl der gewünschten Fokalelemente in der Approximation. M bezeichne die Menge der $k - 1$ am höchsten bewerteten Ereignisse. Dann ist

$$m_S(A) = \begin{cases} m(A), & A \in M \\ \sum_{\substack{A' \subseteq A \\ A' \notin M}} m(A'), & A = A_0 \\ 0, & \text{sonst} \end{cases} \quad (6.52)$$

die Zusammenfassung von m . Dabei ist

$$A_0 = \bigcup_{\substack{A' \notin M \\ m(A') > 0}} A'$$

die durch die Zusammenfassung der gering bewerteten Fokalelemente neu gebildete Teilmenge des Ereignisraumes. Gilt bereits $A_0 \in M$, so werden die Werte aus der zweiten Zeile von (6.52) und $m(A_0)$ addiert.

Für diese Methode gilt:

1. Die Reihenfolge der Kombinationen beeinflusst das Endergebnis.
2. Die Approximation kann für eine Basiswahrscheinlichkeit mit n Fokalelementen in Laufzeit $O(n + \log \log n)$ berechnet werden.

Beispiel 6.5.3 Mit der Basiswahrscheinlichkeit m aus (6.51) und $k = 3$ ergibt sich in diesem Fall m'' mit

$$m''(X) = \begin{cases} 0.5, & X = \{a, b\} \\ 0.3, & X = \{a, c, d\} \\ 0.2, & X = \{c, d, e\} \\ 0, & \text{sonst} \end{cases}$$

In diesem Fall entspricht A_0 der Menge $\{c, d, e\}$.

Behandelten die bisherigen Ausführungen aus der Literatur bekannte Approximationsverfahren, so soll nun der neue Algorithmus D1 vorgestellt werden, dessen Entwicklung zusammen mit der empirischen Untersuchung den wesentlichen Beitrag dieses Abschnitts darstellt. Er beruht auf der Idee, eine bestimmte Anzahl von Fokalelementen aus der gegebenen Basiswahrscheinlichkeit zu entfernen und die ihnen zugeordneten Evidenzmassen an "möglichst naheliegende" andere Teilmengen des Ereignisraumes zuzuweisen. Dabei handelt es sich um ein "konservatives" Verfahren, d.h. die numerischen Werte der entfernten Fokalelemente werden (bzgl. der Kardinalität) größeren Mengen zugeordnet. Somit wird der Grad der Nichtspezifität der Basiswahrscheinlichkeit in jedem Fall erhöht. Der genaue Algorithmus ist in Abbildung 6.19 dargestellt.

Im folgenden seien M^- die Menge der aus der Basiswahrscheinlichkeit m zu entfernenden, M^+ die Menge der beizubehaltenden Fokalelemente.

Abbildung 6.20 gibt ein Beispiel für die Vorgehensweise von D1. Seien etwa $X \in M^-$, $Y_1, \dots, Y_4 \in M^+$. Es existieren keine Ereignisse aus M^+ , die X als Teilmenge enthalten. Y_1, \dots, Y_3 sind die (mengentheoretisch) kleinsten Mengen aus M^+ , die einen nichtleeren Schnitt mit X besitzen. Diese beinhalten insgesamt 3 der 4 Elemente von X (nämlich a, b, d), so daß sich $ratio = 3/4$ ergibt. Insgesamt treten die Elemente von X fünfmal in Y_1, \dots, Y_3 auf, nämlich a, b in Y_1 , d in Y_2 und b, d in Y_3 , so daß diesen jeweils $2/5$ (Y_1 und Y_3) bzw. $1/5$ (Y_2) des zu verteilenden Wertes (nämlich $3/4 \cdot m(X)$) zugewiesen wird. Als Rest von X ergibt sich die Menge $\{c\}$ mit dem Restwert $1/4 \cdot m(X)$, der ebenfalls "oberhalb" von X , d.h. unter den größeren Elementen aus M^+ ,

```

begin D1-Approximation( $m, M^+, M^-$ )
  forall  $X \in M^+$ 
    do  $m_D(X) := m(X)$ 
    od
     $m_D(\Omega) := 0$ 
    forall  $X \in M^-$ 
      do  $distribute(X, |X|)$ 
      od
end

procedure  $distribute(X : set, limit : integer)$ 
 $M_X := \{Y \in M^+ \mid X \subset Y\}$ 
if  $M_X \neq \emptyset$ 
then ;; 1. Fall: es gibt  $M^+$ -Ereignisse, die  $X$  enthalten
   $\hat{M}_X := \{Y \in M_X \mid |Y| \text{ minimal in } M_X\}$ 
  forall  $Y \in \hat{M}_X$ 
    do  $m_D(Y) := m_D(Y) + (1/|\hat{M}_X|) \cdot m(X)$  ;; gleichmäßige Verteilung von  $m(X)$ 
    od ;; unter den kleinsten Elementen von  $\hat{M}_X$ 

else ;; 2. Fall: es gibt keine  $M^+$ -Ereignisse, die  $X$  enthalten
   $M'_X := \{Y \in M^+ \mid |Y| \geq limit, X \cap Y \neq \emptyset\}$ 
  if  $M'_X = \emptyset$ 
    then  $m_D(\Omega) := m_D(\Omega) + m(X)$ 
    fi
     $\hat{M}_X := \{Y \in M'_X \mid |Y| \text{ minimal in } M'_X\}$  ;; sei  $\hat{M}_X = \{Y_1, \dots, Y_l\}$ 
     $ratio := \frac{|\cup_{i=1}^l Y_i \cap X|}{|X|}$  ;; Anteil der Elemente aus  $X$ ,
    ;; die in den  $Y_i$  auftreten
     $number := \sum_{i=1}^l |Y_i \cap X|$  ;; Gesamtzahl der Anteile
    forall  $Y \in \hat{M}_X$ 
      do  $m_D(Y) := m_D(Y) + \frac{|Y \cap X|}{number} \cdot ratio \cdot m(X)$ 
      od
    if  $ratio < 1$ 
      then  $X_{rest} := X \setminus \cup_{i=1}^l Y_i$  ;; noch zu verteilerender Rest von  $X$ 
      if  $X_{rest} \neq \emptyset$ 
        then  $distribute(X_{rest}, limit)$ 
        fi
      fi
    fi
fi

```

Abbildung 6.19: Der Approximationsalgorithmus D1.




Abbildung 6.20: Beispiel für die Arbeitsweise von D1.

aufgeteilt wird. Hier greift der erste Fall, und der Rest von $1/4 \cdot m(X)$ wird vollständig Y_4 zugeteilt.

Für D1 gilt:

1. Die Approximation m_D läßt sich in Laufzeit $O(|M^-| \cdot |M^+|) = O(n^2)$ berechnen.
2. m_D enthält höchstens k Fokalelemente.
3. Die Reihenfolge von Approximationen und Kombinationen beeinflusst das Ergebnis.

Beispiel 6.5.4 Betrachtet man wiederum die Basiswahrscheinlichkeit m aus (6.51) und $k = 3$, so erhält man m_D mit

$$m_D(X) = \begin{cases} 0.5, & X = \{a, b\} \\ 0.475, & X = \{a, c, d\} \\ 0.025, & X = \{a, b, c, d, e\} \\ 0, & \text{sonst} \end{cases}$$

Eine Variante zu D1 ergibt sich, wenn diejenigen Teile der Evidenzmasse, die nicht weiter unter Elementen aus M^+ verteilt werden können, statt an Ω an die Vereinigung all dieser "Reststücke" X_{rest} zugewiesen wird. Da die empirische Untersuchung keinen Unterschied zwischen beiden Methoden ergab, wird im folgenden nur noch die in Abbildung 6.19 dargestellte Version betrachtet.

6.5.2.2 Empirische Untersuchungen

Die Testumgebung zur empirischen Untersuchung der vorgestellten Algorithmen wurde im wesentlichen aus [Tessem, 1993] übernommen. Grundlage für alle Tests war ein Hypothesenraum der Größe $|\Omega| = 32$. Für jeden Algorithmus wurden nun zufällige Basiswahrscheinlichkeiten mit jeweils 8 Fokalelementen erzeugt und 5 Kombinationen mit Dempsters Regel durchgeführt. Nach jeder Kombination wurden die Ergebnisse approximiert und die Abweichungen bzgl. der Fehlermaße Error1 – Error3 berechnet. Für jeden Algorithmus wurden mehr als 1000 Versuche durchgeführt.¹⁰

Der Algorithmus zur Berechnung einer zufälligen Basiswahrscheinlichkeit ist folgender. Sei X eine exponentiell verteilte reell-wertige Variable.

```

begin Restmasse := 1
  for  $i := 1$  to 7
    do erzeuge Zufallszahl  $X$ 
      wähle "neues"  $A \subseteq \Omega$ 
       $m(A) := X \cdot \textit{Restmasse}$ 
       $\textit{Restmasse} := \textit{Restmasse} - X \cdot \textit{Restmasse}$ 
    od
    wähle "neues"  $A \subseteq \Omega$ 
     $m(A) := \textit{Restmasse}$ 
end

```

Es wurden folgende Instantiierungen der vorgestellten Approximationsalgorithmen untersucht (die Namen entsprechen den Markierungen in den nachfolgenden Grafiken):

D1_8: D1 mit $k = 8$

D1_30: D1 mit $k = 30$

Summ_8: Summarization $k = 8$

Summ_30: Summarization $k = 30$

Bayes: Bayessche Approximation

klx01: $k - l - x$ mit $k = 1$, $l = \infty$, $x = 0.01$.¹¹

klx_30: $k - l - x$ mit $k = 1$, $l = 30$, $x = 1.0$

Die theoretisch maximal mögliche Anzahl von Fokalelementen nach der 5. Kombination ist $8^5 = 32768$ (die Größe des Hypothesenraumes ist etwa $4.3 \cdot 10^9$).

¹⁰In [Tessem, 1993] wurden außerdem Basiswahrscheinlichkeiten mit 2 und 4 Fokalelementen betrachtet.

¹¹Diese Werte wurden [Tessem, 1993] entnommen.

Die Abbildungen 6.21 – 6.23 zeigen die Ergebnisse der empirischen Untersuchungen gemäß obigem Vorgehen. Dabei sind auf der X -Achse die Anzahl der Kombinationen, auf der Y -Achse die jeweiligen Fehler aufgetragen.

Zusammenfassung der Ergebnisse

Die *klx01* Approximation schneidet bei allen Fehlermaßen am besten ab. Dieses Ergebnis ist dadurch zu erklären, daß hier nur einige extrem niedrig bewertete Fokalelemente aus der Basiswahrscheinlichkeit entfernt werden (insgesamt nur 0.01 der Gesamtmasse), so daß durchschnittlich 440, maximal sogar über 1800 Fokalelemente verbleiben. Die Größe der ursprünglichen *bpa*'s wurde durchschnittlich auf etwas mehr als ein Viertel reduziert (vergleiche Tabelle 6.7). Das Laufzeitverhalten ist dennoch wesentlich schlechter als das aller anderen Methoden.

Wird dagegen die Anzahl der Fokalelemente wie bei *klx30* beschränkt, so verbessert sich zwar die Laufzeit, jedoch sind die Abweichungen der pignistischen Wahrscheinlichkeiten sehr hoch (siehe Error1).

Die beiden Instantiierungen der "Summarization" schneiden bzgl. aller Fehlermaße am schlechtesten ab (verglichen mit den anderen Approximationen mit jeweils gleicher Anzahl an Fokalelementen).

Die Bayessche Approximation ist die einzige, deren Abweichungen von den tatsächlichen Werten mit der Anzahl der Kombinationen geringer werden. In [Tessem, 1993] wird dies dadurch erklärt, daß Basiswahrscheinlichkeiten, die durch die Kombination vieler Evidenzen entstehen, immer spezifischer werden und sich somit diskreten Wahrscheinlichkeitsverteilungen annähern. Dieser Algorithmus bringt somit die größten Fehler mit sich, wenn sehr schnell Entscheidungen getroffen werden müssen, d.h. wenn erst sehr wenig Information zur Verfügung steht. Bei der 4.-5. Kombination erreicht er ungefähr die Werte von D1_30.

Der D1 Algorithmus schließlich liefert bereits bei $k = 8$ relativ gute Werte (vor allem bei Error2 und Error3), was bei extrem zeitkritischen Anwendungen die Entscheidungsunterstützung erleichtert. Für $k = 30$ sind seine Abweichungen während der ersten Kombinationen die besten aller untersuchten Methoden (mit Ausnahme von *klx01*). Nach etwa 4 bis 5 Kombinationen wird er von der Bayesschen Approximation erreicht, die ab dann etwas bessere Werte liefert.

Der MYCIN-Algorithmus wurde hier nicht weiter empirisch untersucht, da die Qualität der Approximation stark von der vorgegebenen Struktur des verbleibenden Hypothesenraums T abhängt. Insbesondere die Tiefe des Baumes T , d.h. die verbleibende Anzahl der "Abstraktionsebenen", beeinflußt die Abweichung von der pignistischen Wahrscheinlichkeit.

Bei der Entscheidung für einen dieser Approximationsalgorithmen müssen deren unterschiedliche Eigenschaften gegeneinander abgewogen werden. Ist die Laufzeit weniger kritisch, so ist *klx01* (oder eine vergleichbare Instantiierung dieser Methode) die beste Wahl. Sind nur bis zu $|\Theta|$ viele Fokalelemente vertretbar, so liefern D1_30 und die Bayessche Approximation die besten Ergebnisse, wobei ersterer während der ersten Kombinationen, letzter erst bei längeren Zyklen Vorteile aufweist. Ist aufgrund

	Anzahl der Fokalelemente					
	ϕ real	ϕ approx	min real	max real	min approx	max approx
D1_8	1624	8.7	213	7058	7	9
D1_30	1616	29.93	208	4590	29	31
Summ_8	1680	8	209	5859	8	8
Summ_30	1589	30	188	4404	30	30
Bayes	1632	29.32	217	5806	23	31
klx01	1616	440	234	4447	3	1849
klx_30	1448	28.63	179	2763	13	31

Tabelle 6.7: Quantitativer Vergleich der Approximationsalgorithmen.

von Zeitrestriktionen nur eine sehr grobe Approximation möglich, so schneidet D1 am besten ab.

Weiterhin ist zu beachten, daß in der Bayesschen Approximation die Vertrauensintervalle zu Punkten verkleinert werden, so daß die Information über die Unsicherheit dieser numerischen Bewertung selbst vollständig verlorenght. Dies äußert sich darin, daß der Grad der Nichtspezifität einer solchen approximierten bpa immer den Wert Null hat (vergleiche dazu Definition 6.3.4). Somit ist es nicht mehr möglich, hochgradig unterspezifizierte Situationen zu erkennen und gegebenenfalls eine Entscheidung zu verschieben, bis exaktere Informationen zur Verfügung stehen.

Tabelle 6.7 gibt einen Überblick über einige wichtige Daten der empirischen Versuche, nämlich die durchschnittliche Anzahl der Fokalelemente in den ursprünglichen und approximierten Basiswahrscheinlichkeiten sowie deren jeweiliges Minimum und Maximum.




Abbildung 6.21: Ergebnisse bzgl. Error1.




Abbildung 6.22: Ergebnisse bzgl. Error2.

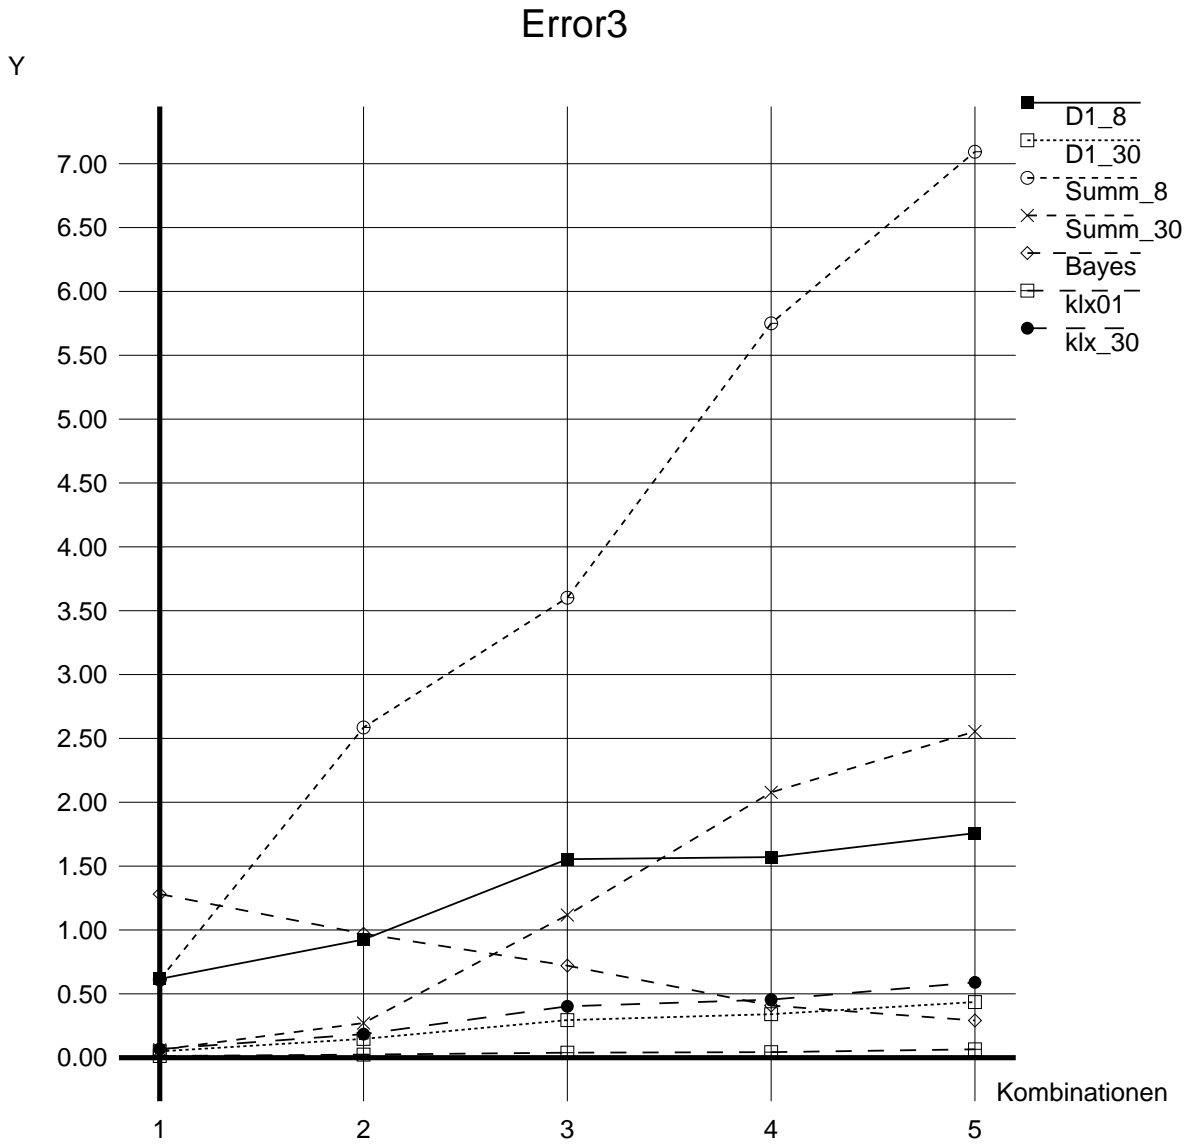


Abbildung 6.23: Ergebnisse bzgl. Error3.

6.6 Verfeinerung des Benutzermodells durch maschinelles Lernen

Dieser Abschnitt beschreibt eine Einschränkung des bisher vorgestellten Systems zur Planerkennung unter Unsicherheit und deren Behebung durch den Einsatz von Techniken aus dem Bereich des maschinellen Lernens. Das Ergebnis dieser Erweiterung ist ein verfeinertes Benutzermodell, das in der Lage ist, nahezu das gesamte typische Verhalten eines Agenten abzudecken. Somit wird der Planerkennungsprozeß zuverlässiger in dem Sinn, daß nun große Teile der Handlungen eines Agenten schnell identifiziert werden können. Eine konkrete Anwendung im Rahmen des Systems RAP wird in Abschnitt 7.4 vorgestellt.

6.6.1 Motivation

Die in Abschnitt 6.3 vorgestellte Version des quantitativen Benutzermodells zielt darauf ab, *typische* Verhaltensmuster eines Agenten numerisch zu erfassen. Als "typisch" gilt dabei das gehäufte Auftreten bestimmter Pläne im Langzeitverhalten eines Agenten sowie im Zusammenhang mit dessen beobachteten Aktionen. Das folgende Beispiel wird veranschaulichen, daß diese Information mitunter nicht ausreichend ist, um das Verhalten eines Agenten korrekt vorhersagen zu können.

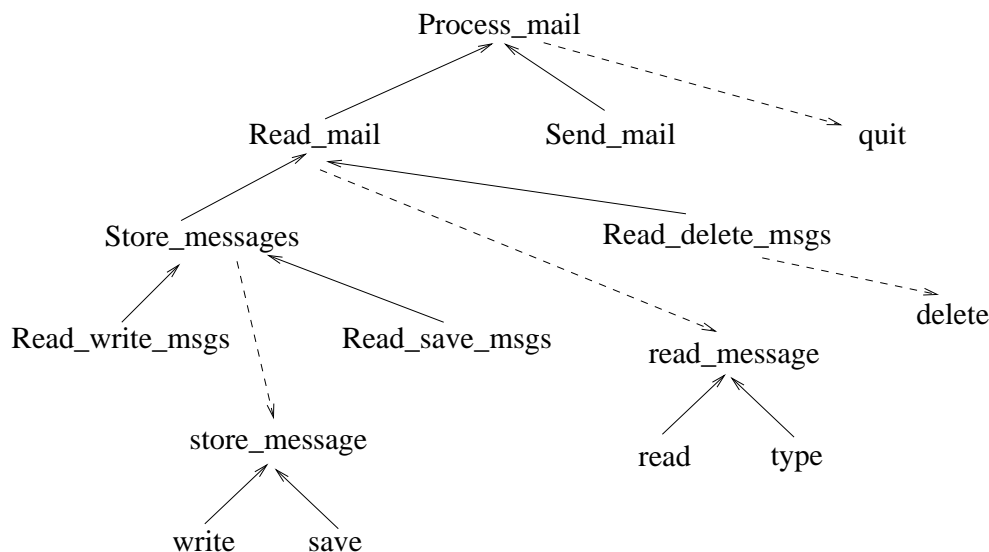



Abbildung 6.24: Beispiel einer Planhierarchie für die email-Domäne.

Beispiel 6.6.1 Angenommen, ein bestimmter Benutzer eines email-Systems pflegt alle Nachrichten, die er erhält, abzuspeichern. Die einzige Ausnahme bilden die recht seltenen Mitteilungen seines Chefs, die er nach dem Lesen prinzipiell löscht. Um dieses Szenario im Rahmen der bisher vorgestellten Konzepte formalisieren zu können, sei

die Planhierarchie aus Abbildung 6.24 gegeben. Die zusätzliche Information über das Verhalten des Benutzers kann mittels folgender gewichteten Beobachtungsregel kodiert werden.



Dabei spielen die numerischen Gewichte selbst eine untergeordnete Rolle. Lediglich die Größenordnungen dieser Werte sind von Interesse. Wird nun der oben erwähnte Benutzer beim Lesen einer Nachricht, die ihm sein Chef geschickt hat, beobachtet, so kommt die angegebene Beobachtungsregel zur Anwendung. Ihr Effekt ist eine numerische Hypothesenbewertung, die dem Plan Store_messages einen deutlich größeren Wert als allen anderen Hypothesen zuordnet. Dies bedeutet, daß das typische Verhalten des Benutzers als Reaktion auf eine bestimmte Art von Situationen nicht erkannt wird. Ursache dafür ist das Schema, nach dem die Beobachtungsregeln angewandt werden. Dieses berücksichtigt lediglich die Constraints zwischen der Aktion in der Prämisse und den Hypothesen in der Konklusion der Regeln, vernachlässigt also die aktuelle Situation, in der eine Aktion ausgeführt wird, obwohl diese – wie im obigen Fall – wertvolle Information über das wahrscheinliche Benutzerverhalten beinhalten kann.

Die Verhaltensmuster, die durch den bisherigen Ansatz nicht oder nur unzureichend erkannt werden können, lassen sich charakterisieren als

sich wiederholende gleichartige Reaktionen eines Agenten auf bestimmte Klassen von Situationen, die – gemessen am Langzeitverhalten des Agenten – seltener auftreten als andere.

Es liegt daher nahe, das Benutzermodell um eine Beschreibung der Zusammenhänge zwischen bestimmten Situationen und entsprechenden Reaktionen zu erweitern, um somit ein Modell der *Benutzerpräferenzen* zu erhalten, d.h. seiner Motivation, in einer bestimmten Art und Weise auf einen bestimmten Zustand der Welt zu reagieren (siehe dazu auch [Bauer, 1996a]).

Anmerkung: Wie die obige Charakterisierung der Einschränkungen des bisher vorgestellten Ansatzes zur Planerkennung bereits deutlich macht, handelt es sich bei den “problematischen” Fällen um relativ seltene Abweichungen des Agenten von seinem Langzeitverhalten, die jedoch durch den jeweils aktuellen Zustand der Welt bedingt werden. In vielen Anwendungen wird es daher ausreichen, ein quantitatives Benutzermodell in der in Abschnitt 6.3 vorgestellten Form zu verwenden. Werden jedoch höhere Anforderungen an die Zuverlässigkeit (und Geschwindigkeit) der Erkennung gestellt, so sind die im Folgenden vorgestellten Techniken überlegen.

Um dabei eine kompakte Repräsentation zu erhalten, ist es notwendig, diese Situationen bzgl. gemeinsamer Eigenschaften zu *klassifizieren*, so daß die Regelmäßigkeiten in der Reaktion des Benutzers auf solche *Klassen* von Weltzuständen erkannt und für die Planerkennung verwendet werden können. Da in vielen Anwendungen wie intelligenten Hilfesystemen der Benutzer üblicherweise nicht gewillt ist, diese Information dem System direkt mitzuteilen, bietet sich die Verwendung von Techniken des maschinellen Lernens zur Gewinnung dieser Daten an.¹²

Neben der Tatsache, daß i.a. keine Benutzerunterstützung beim Aufbau eines solchen Modells erwartet werden kann, ist die Lernaufgabe durch folgende weitere Eigenschaften charakterisiert. Da die verschiedenen Situationen oder Weltzustände bzgl. der jeweiligen Reaktion des Agenten klassifiziert werden sollen, handelt es sich hierbei um eine Instanz des “überwachten Lernens” (supervised learning), bei dem ein “Lehrer” – in diesem Fall ein Planerkennungssystem – die Klassenzugehörigkeit der präsentierten Trainingsbeispiele vorgibt (siehe dazu auch [Dietterich und Michalski, 1983] und [Shavlik und Dietterich, 1990, Kapitel 2]).

Weiterhin sollen Situationen mit einer möglichst einfachen Sprache repräsentiert werden. Die einfachste Möglichkeit ist hierbei die Darstellung mittels einer vordefinierten Menge von Attributen. Dies erlaubt gerade in Softwareanwendungen die einfache Bestimmung aller zur Kodierung einer neuen Instanz notwendigen aktuellen Werte.

Weiterhin ist es gegebenenfalls erforderlich, mit “verrauschten” Daten umzugehen. Dies ist immer dann der Fall, wenn in einer Anwendung die tatsächlichen Werte der eine Situation beschreibenden Attribute nicht exakt ermittelt werden können. Dabei kann es zu einer inkorrekten Klassifizierung kommen, die die Trainingsbeispiele nur zu einem bestimmten Prozentsatz korrekt erfaßt.

Schließlich sollte eine Erklärungskomponente, wie sie in Abschnitt 6.2.2 beschrieben wurde, unterstützt werden in dem Sinne, daß präzise und kompakte Rechtfertigungen der vom System gelieferten Ergebnisse auf einer gewissen Abstraktionsebene ermöglicht werden.

Aufgrund dieser Anforderungen fiel die Entscheidung für ein Lernverfahren aus der TDIDT-Familie (“top-down induction of decision trees”), die aus dem ID3 Algorithmus von Quinlan [1983] hervorgegangen ist. Die folgenden Abschnitte stellen diese Verfahren vor, erläutern die Anwendung auf das Problem der Planerkennung und diskutieren verwandte Arbeiten.

6.6.2 Induktion von Entscheidungsbäumen

Dieser Abschnitt wird sich auf die Beschreibung des ID3 Lernalgorithmus aus [Quinlan, 1983] beschränken, da dieser alle wesentlichen Merkmale der TDIDT Familie

¹²Daneben ist es denkbar, daß der Agent selbst sich solcher Regelmäßigkeiten in seinem Verhalten überhaupt nicht bewußt ist, so daß ein direkter Wissenserwerb durch dessen Befragung diese Zusammenhänge nicht aufdecken kann. Beispiele dafür finden sich im Bereich der Tutoringsysteme, wenn etwa ein Anwender immer wieder das gleiche suboptimale Verhalten bei einer bestimmten Problemklasse zeigt.

aufweist. Alle Nachfolger von ID3 erweitern diesen lediglich um Aspekte wie die Behandlung von Attributen mit ganzzahligen oder kontinuierlichen Wertebereichen, Inkrementalität oder Berücksichtigung verrauschter Daten. Für einen genaueren Überblick über diese Methoden sei hier auf [Dietterich und Michalski, 1983; Quinlan, 1986a; Quinlan, 1986b] verwiesen.

Die Eingabe von ID3 bildet eine Menge von *Trainingsbeispielen*, die durch Angabe verschiedener Attributwerte eindeutig charakterisiert und jeweils einer aus einer Reihe paarweise disjunkter Objektklassen zugeordnet sind. Ziel ist es nun, einen Entscheidungsbaum aufzubauen, dessen Knoten jeweils einen elementare Test bzgl. eines bestimmten Attributes beinhalten und die Trainingsinstanzen in Abhängigkeit vom Ergebnis dieses Tests auf die darunterliegenden Teilbäume verteilen. Das Testen wird beendet, sobald alle Instanzen in einem Blatt des Baumes zur gleichen Klasse gehören. Neben einem Klassenzugehörigkeitstest implementiert ein solcher Entscheidungsbaum somit auch eine abstrakte Beschreibung einer Objektklasse, d.h. ein *Konzept*. Ein solcher Baum, der alle Trainingsbeispiele korrekt klassifiziert, kann verwendet werden, um Vorhersagen über die Klassenzugehörigkeit bisher unbekannter Instanzen zu treffen.

Anmerkung: Befinden sich in einem Blatt des Entscheidungsbaumes Instanzen unterschiedlicher Klassen, die jedoch ausschließlich übereinstimmende Attributwerte aufweisen, so ist dies ein Hinweis darauf, daß die vorgegebene Menge von Attributen zur Klassifizierung nicht geeignet ist. Geht man allerdings davon aus, daß die Trainingsbeispiele nicht unbedingt korrekt klassifiziert sein müssen, so wird ein solcher Fall als "Noise" behandelt.

Um nun zu möglichst einfachen Entscheidungsbäumen zu kommen, ist es wichtig, zu jedem Zeitpunkt genau das Attribut zu testen, das die meiste Information bzgl. der im aktuellen Teilbaum zu behandelnden Trainingsbeispiele liefert. ID3 verwendet zur Steuerung dieser Auswahl ein informationstheoretisches Maß. Seien P und N die beiden Klassen, zu denen alle Trainingsinstanzen gehören.¹³ Die Menge C der Trainingsbeispiele enthalte p Elemente aus P und n aus N . ID3 geht dann von folgenden Annahmen aus:

1. Ein korrekter Entscheidungsbaum für C klassifiziert Objekte im selben Verhältnis wie sie in C auftreten. D.h. für ein beliebiges Objekt aus C ist die Wahrscheinlichkeit, zu P zu gehören, gerade $p/(n+p)$ (und $n/(n+p)$ für N).
2. Wird ein Entscheidungsbaum zur Klassifikation eines Objektes verwendet, so liefert er eine Klasse zurück, d.h. er kann als eine Informationsquelle für die Mitteilung P oder N betrachtet werden, wobei die erwartete Information zur Generierung dieser Mitteilung gegeben ist durch

$$I(p, n) = -\frac{p}{p+n} \log_2 \frac{p}{p+n} - \frac{n}{p+n} \log_2 \frac{n}{p+n}$$

¹³ID3 behandelt ausschließlich die Induktion von Entscheidungsbäumen für diesen binären Fall. Die Verallgemeinerung auf mehrere solcher Klassen ist jedoch sehr einfach.

Wird ein Attribut A mit den Werten a_1, \dots, a_v an der Wurzel des Baumes getestet, so partitioniert dies C in die Mengen C_1, \dots, C_v , wobei alle Elemente von C_i den Wert a_i für A besitzen. C_i enthalte p_i (n_i) Objekte der Klasse P (N). Die erwartete Information, die für den Baum mit Wurzel A erforderlich ist, ist somit

$$E(A) = \sum_{i=1}^v \frac{p_i + n_i}{p + n} I(p_i, n_i).$$

Der *Informationsgewinn* beim Testen von A ist daher

$$\text{gain}(A) = I(p, n) - E(A).$$

ID3 versucht, diesen Wert bei der Auswahl des nächsten zu testenden Attributes zu maximieren.

Beispiel 6.6.2 [Quinlan, 1986a] Gegeben seien die in Tabelle 6.8 dargestellten Trainingsbeispiele. Ziel ist es, verschiedene Wettervorhersagen in die Klassen P und N einzuteilen und die entsprechenden abstrakten Konzepte für diese Klassen zu bilden.

Attribute				Klasse
Aussichten	Temperatur	Luftfeuchtigkeit	Wind	
sonnig	heiß	hoch	nein	N
sonnig	heiß	hoch	ja	N
bedeckt	heiß	hoch	nein	P
regnerisch	mild	hoch	nein	P
regnerisch	kühl	normal	nein	P
regnerisch	kühl	normal	ja	N
bedeckt	kühl	normal	ja	P
sonnig	mild	hoch	nein	N
sonnig	kühl	normal	nein	P
regnerisch	mild	normal	nein	P
sonnig	mild	normal	ja	P
bedeckt	mild	hoch	ja	P
bedeckt	heiß	normal	nein	P
regnerisch	mild	hoch	ja	N

Tabelle 6.8: Trainingsbeispiele für ID3.

Von diesen 14 Objekten gehören 9 zu P und 5 zu N . Die zur Klassifikation notwendige Information ist

$$I(p, n) = \frac{9}{14} \log_2 \frac{9}{14} - \frac{5}{14} \log_2 \frac{5}{14} = 0.940$$

Beim Attribut “Aussichten” nehmen 5 den Wert “sonnig” an, von denen 2 zu P und 3 zu N gehören. Somit ergibt sich mit $p_1 = 2$ und $n_1 = 3$ der Wert

$$I(p_1, n_1) = 0.971.$$

Für “bedeckt” und “regnerisch” mit den Werten $p_2 = 4, n_2 = 0$ bzw. $p_3 = 3, n_3 = 2$ erhält man ferner

$$I(p_2, n_2) = 0, \quad I(p_3, n_3) = 0.971.$$

Das erwartete Informationsbedürfnis nach dem Test dieses Attributes ist somit

$$E(\text{Aussichten}) = 0.694.$$

Der Informationsgewinn durch diesen Test beträgt somit

$$\text{gain}(\text{Aussichten}) = 0.246.$$

Abbildung 6.25 zeigt den von ID3 anhand dieser Trainingsmenge erzeugten Entscheidungsbaum.

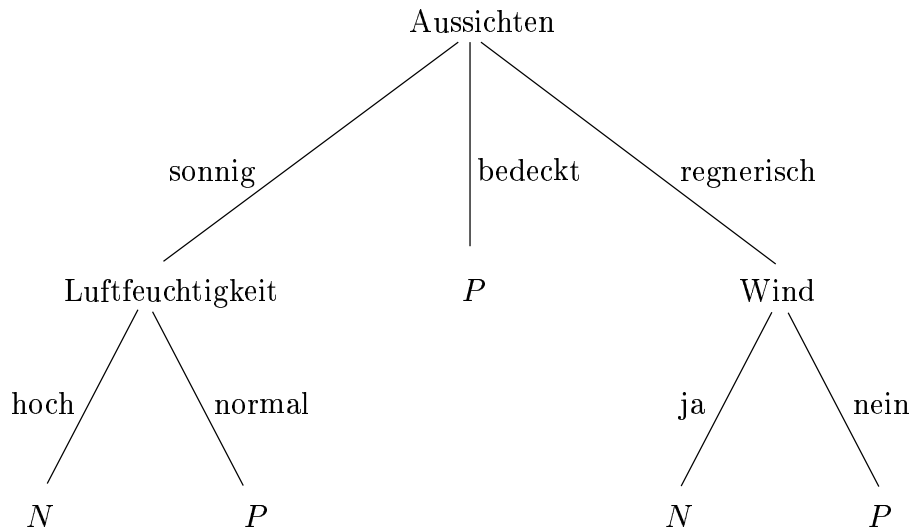


Abbildung 6.25: Der von ID3 erzeugte Entscheidungsbaum.

Anhand dieses Baumes wird deutlich, wie ID3 aus den extensional als Teilmengen von C gegebenen Klassen N und P die abstrakten Konzeptbeschreibungen induziert. Das Verfolgen der Pfade von der Wurzel des Entscheidungsbaumes zu den Blättern liefert eine intensionale Charakterisierung dieser Konzepte und wird bei der Erklärung der Planerkennungsergebnisse eine wichtige Rolle spielen.

Neben einer einfachen Repräsentationssprache für Objekte wurde in Abschnitt 6.6.1 die Fähigkeit zum Umgang mit verrauschten Daten für bestimmte Anwendungsfelder gefordert. Dies sowie die Erweiterung um die Behandlung kontinuierlicher Attribute

werden in den Arbeiten [Quinlan, 1986b; Quinlan, 1986a] und [Quinlan, 1996] behandelt.

Neuere Entwicklungen im Bereich des induktiven Lernens durch Beispiele zielen darauf ab, die kategorischen Unterscheidungen abzuschwächen, die durch die Entscheidungsbäume selbst zwischen benachbarten Attributwerten gezogen werden. Somit soll einerseits der potentiellen Unsicherheit einer Klassifikation Rechnung getragen, andererseits der abrupte Wechsel von einer Objektklasse zu einer anderen aufgrund einer minimalen Veränderung eines Attributwertes verhindert werden (“soft thresholds”). Die Algorithmen C4 [Quinlan, 1990] und C4.5 [Quinlan, 1993; Quinlan, 1996] zählen zu dieser Kategorie. Weitere aktuelle Ansätze beziehen sich auf das Lernen von Bayesischen Netzen (siehe u.a. [Heckerman, 1995; Friedman und Goldszmidt, 1996]).

6.6.3 Anwendung auf die Planerkennung

Dieser Abschnitt behandelt die konkrete Anwendung der oben vorgestellten Lernverfahren in der Benutzermodellierung und Planerkennung. Als Beispieldomäne wird hier die Benutzung eines email-Systems betrachtet.

6.6.3.1 Die Trainingsphase

Um ein Modell der Regelmäßigkeiten in den Reaktionen eines Agenten zu erstellen, ist es notwendig, zunächst eine Menge von Attributen vorzugeben, mit deren Hilfe die wesentlichen Aspekte von *Situationen* beschrieben werden sollen. Ziel ist es, die jeweils verfolgten Pläne aus einer gegebenen Planhierarchie als *Klassen* (im Sinne von N und P in Abschnitt 6.6.2) zu verwenden, um somit abstrakte Beschreibungen von Situationen zu erzeugen, die zu jeweils gleichen Situationen geführt haben.

Um die folgenden Ausführungen möglichst einfach zu halten, werden zur Beschreibung einer Situation neben der aktuellen Aktion lediglich die Länge und der Absender der aktuellen Nachricht verwendet. Während dies ausreichend für die Diskussion der prinzipiellen Vorgehensweise ist, erfordert eine realistischere Modellierung die Berücksichtigung einer deutlich größeren Anzahl von Attributen. Ähnlich wie beim intelligenten email-Assistenten Maxims [Maes, 1994] müßten dazu zusätzlich der Empfänger, die Inhalte der **Cc:** und **Subject:** Felder, der aktuelle Status der Nachricht (gelesen, gelöscht, ...) usw. einbezogen werden.

Die Trainingsbeispiele, die zur Induktion dieser abstrakten Klassenbeschreibungen verwendet werden, haben somit folgende Form

$$[\langle \text{action} \rangle, \langle \text{sender} \rangle, \langle \text{length} \rangle, \langle \text{plan} \rangle].$$

Sie werden während der Trainingsphase auf folgende Weise gewonnen. Bei jeder Aktion a , die der beobachtete Benutzer ausführt, werden die Attributwerte der aktuellen Situation – im vorliegenden Fall also der Absender s und die Länge l der momentan bearbeiteten Nachricht – ermittelt und ein entsprechender Eintrag $[a, s, l]$ in eine Datenbasis DB eingefügt.

Der aktuelle Planerkennungszyklus endet, sobald der Plan des Benutzers erkannt wurde oder dessen Interaktion mit dem email-System endet. Im ersten Fall liefert der Planerkenner als Ergebnis einen Basisplan p aus einer Planhierarchie wie in Abbildung 6.24. Im zweiten Fall ist das Ergebnis die Menge P aller Pläne, die mit allen beobachteten Aktionen des Benutzers kompatibel waren. Diese im allgemeinen mehr-elementige Menge kann, wie bereits erwähnt, als abstrakter Plan interpretiert werden. Ist $P = \emptyset$, entsprach das Vorgehen des Benutzers also keinem der in der Planhierarchie vorgegebenen Pläne, so werden alle DB -Einträge dieses Zyklus wieder entfernt.

Am Ende der Trainingsphase werden alle so markierten Einträge der Datenbasis DB , die jeweils die gleiche Aktion beinhalten, an eine modifizierte Version des in Abschnitt 6.6.2 vorgestellten Lernalgorithmus übergeben. Dabei repräsentiert die Markierung eines Eintrags mit einer Planmenge P deren Klassifizierung. Der so entstehende Entscheidungsbaum für eine Aktion a wird mit $T(a)$ bezeichnet. Wie aus der folgenden Diskussion ersichtlich, repräsentiert er die statistischen Zusammenhänge zwischen dem Auftreten von a als Bestandteil verschiedener Pläne und bestimmten Klassen von Situationen.

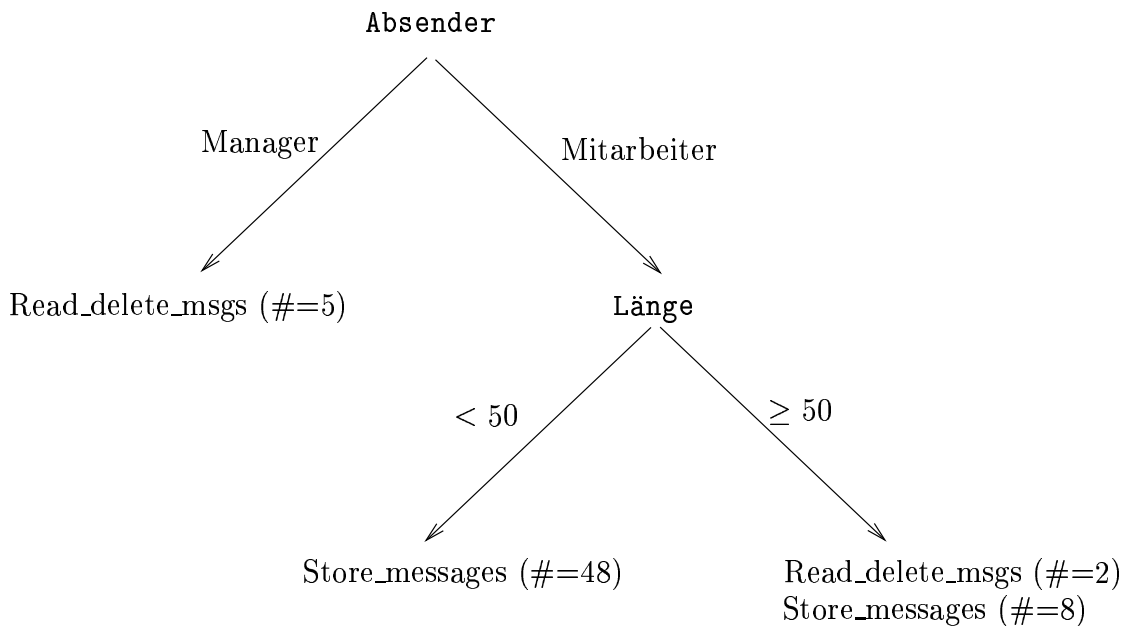
Beispiel 6.6.3 In Abbildung 6.26 ist exemplarisch der Entscheidungsbaum für die abstrakte Aktion `read_message` dargestellt. Grundlage für seine Generierung war folgender Inhalt von DB :

- 5 Einträge der Form [`read_message`, `Manager`, `*`, `Read_delete_msgs`]¹⁴
- 48 Einträge [`read_message`, `Mitarbeiter`, l , `Store_messages`] mit $l < 50$
- 2 Einträge [`read_message`, `Mitarbeiter`, l , `Read_delete_msgs`] mit $l \geq 50$ und
- 8 Einträge [`read_message`, `Mitarbeiter`, l , `Store_messages`] mit $l \geq 50$

Die jeweiligen Häufigkeiten werden in den Blättern der Entscheidungsbäume durch $\# = n$ angezeigt. Sie werden bei der Berechnung von Hypothesenbewertungen eine Rolle spielen.

Dieser Baum repräsentiert folgende Information. In allen fünf Fällen, in denen der Benutzer eine Nachricht seines Managers las (d.h. die Aktion `read_message` ausführte), verfolgte er den Plan `Read_delete_msgs`. Wann immer er eine Nachricht eines Mitarbeiters las, die weniger als 50 Zeilen Länge hatte, speicherte er sie ab, führte also den Plan `Store_messages` aus (dies wurde 48 mal beobachtet). Überschritt die Länge der aktuell gelesenen Nachricht die Länge von 50 Zeilen, so wurde diese manchmal gelöscht (dies war zweimal der Fall) und manchmal abgespeichert (achtmal).

¹⁴Dabei steht `*` für einen beliebigen Attributwert.

Abbildung 6.26: Der Entscheidungsbaum $T(\text{read_message})$.**Anmerkungen:**

1. Offensichtlich sind in diesem letzten Fall die zur Beschreibung einer Situation ausgewählten Attribute nicht zur eindeutigen Klassifizierung geeignet. Dies stellt aber im Hinblick auf die Bewertung von Planhypothesen kein Problem dar, sondern verhindert sogar vielmehr eine zu starke Differenzierung ähnlicher Situationen.
2. Um dieses "Overfitting" zu vermeiden, werden Attributwerte, die nur vereinzelt auftreten, vor Beginn der Berechnung eines Entscheidungsbaumes mit Hilfe einer vorgegebenen Taxonomie abstrahiert. So werden beispielsweise einzelne Absender von Nachrichten zur abstrakten Klasse der "Mitarbeiter" zusammengefaßt. Würde man dies nicht tun, so müßte beim Test dieses Attributes für alle möglichen Absender eine eigene Verzweigung eingeführt werden. Es wäre zwar weiterhin möglich, einen korrekten Entscheidungsbaum zu induzieren, jedoch gingen dabei die inhärenten Regelmäßigkeiten verloren.
3. Das mehrfache Auftreten des abstrakten Planes Store_messages im Entscheidungsbaum deutet darauf hin, daß in vielen Fällen der Plan des Benutzers nicht eindeutig identifiziert werden konnte.
4. Tritt eine Aktion a während der Trainingsphase nicht auf, so besteht der entsprechende Entscheidungsbaum $T(a)$ aus einem einzigen Knoten, der alle möglichen Situationen auf die Menge aller a enthaltenden Pläne abbildet. Diese Information kann direkt aus der Planhierarchie gewonnen werden.

5. Auf der Basis derselben Beobachtungen hätten sich mit der bisherigen Methode durch Initialisierung gemäß (6.3) (siehe Seite 109) und schrittweise Aktualisierung gemäß (6.45) (siehe Seite 172) Werte in der Größenordnung von 0.89 für `Store_messages` und 0.11 für `Read_delete_msgs` ergeben.

6.6.3.2 Der Planerkennungsprozeß

Am Ende der Trainingsphase, während der der bisherige Ansatz zur Hypothesenbewertung bereits verwendet werden kann, besteht das Benutzermodell aus einer Menge von Entscheidungsbäumen $T(a)$ für alle Aktionen a . Der Planerkennungsprozeß selbst findet nun in vier Schritten statt.

1. Sobald der Agent eine neue Aktion a_0 ausführt, werden die relevanten Attributwerte der aktuellen Situation s_0 ermittelt, und ein entsprechender Eintrag $[a_0, s_0]$ wird in die Datenbasis aufgenommen.
2. Diese Situationsbeschreibung wird mit Hilfe des Baumes $T(a_0)$ klassifiziert. Auf der Basis dieses Ergebnisses und zusätzlicher Information vom Planerkenner wird eine numerische *Hypothesenstärke* \hat{r} berechnet.
3. Diese wird mit der aktuellen Hypothesenbewertung m_i zur neuen Bewertung m_{i+1} kombiniert.
4. Am Ende des Planerkennungszyklus werden die gesammelten Daten wie in Abschnitt 6.6.3.1 beschrieben mit dem Erkennungsergebnis markiert. Gegebenenfalls werden die Entscheidungsbäume $T(a)$ mittels der Information aus diesem letzten Zyklus aktualisiert.

Dieses Vorgehen wird im folgenden anhand eines Beispiels näher erläutert.

Beispiel 6.6.4 Angenommen, die erste Aktion des Benutzers ist `read_message`, die aktuelle Nachricht war von seinem Chef und hatte die Länge 30, d.h. $s_0 = [\text{Manager}, 30]$. Die Klassifikation mit Hilfe des Baumes aus Abbildung 6.26 führt zu der Annahme, daß diese Aktion definitiv zum Plan `Read_delete_msgs` gehört (der Test bzgl. des Absenders führt zum linken Blatt). Da diese Annahme jedoch auf einer relativ kleinen Menge statistischer Daten beruht – in diesem Fall auf lediglich 5 gleich gelagerten Beispielen –, muß die mangelnde Zuverlässigkeit dieser Informationen und der darauf basierenden Schlußfolgerungen berücksichtigt werden.

Zu diesem Zweck werden die relativen Häufigkeiten aller in einem Blatt auftretenden Pläne durch Anwendung der in Definition 6.2.2 beschriebenen Operation um einen gewissen Betrag α reduziert. Die Zuweisung des verbleibenden numerischen Wertes an die unspezifischste Hypothese \mathcal{P}_0 repräsentiert wiederum die durch die Unzuverlässigkeit der Informationsquellen bedingte partielle Unwissenheit hinsichtlich der Hypothesenbewertung.¹⁵ Ein solcher Faktor α ist mit jedem Blatt eines Entscheidungsbaumes assoziiert. Er wird mit wachsender Anzahl der darin repräsentierten Instanzen schrittweise verringert, bleibt jedoch stets > 0 .

¹⁵Liegt auch negative Information der Art vor, daß bestimmte Pläne ein Auftreten einer bestimmten Aktion explizit ausschließen, so wird dieser verbleibende Wert der Menge aller mit dieser Aktion verträglichen Pläne zugewiesen.

Für obigen Fall ergibt sich mit einem Zuverlässigkeitsfaktor von $\alpha = 0.8$ die Hypothesenstärke

$$\hat{r}(X) = \begin{cases} 0.8, & X = \{\text{Read_delete_msgs}\} \\ 0.2, & X = \mathcal{P}_0 \\ 0.0, & \text{sonst} \end{cases} \quad (6.53)$$

Dieses Resultat entspricht dem intuitiv “korrekten” Ergebnis für das Beispiel aus Abschnitt 6.6.1. Ohne die Verwendung des verfeinerten Benutzermodells hätten sich

Die Behandlung der Constraints zwischen der Aktion und den einzelnen Plänen erfolgt wie in Abschnitt 6.2 beschrieben.

Wäre die aktuelle Nachricht hingegen von einem Mitarbeiter und hätte beispielsweise die Länge 70, so ergäben sich mit $\alpha = 0.9$ folgende Werte

$$\hat{r}(X) = \begin{cases} 0.18, & X = \{\text{Read_delete_msgs}\} \\ 0.72, & X = \text{Store_messages} \\ 0.10, & X = \text{Read_mail} \\ 0.0, & \text{sonst} \end{cases} \quad (6.54)$$

Dabei wird angenommen, daß `read_message` mit dem Plan `Send_mail` nicht verträglich ist d.h. nicht darin vorkommen darf.

6.6.3.3 Erklärung der Ergebnisse

Im Wesentlichen können zur Erklärung der auf der Basis des verfeinerten Benutzermodells erzielten Planerkennungsergebnisse die Techniken aus Abschnitt 6.2.2.2 verwendet werden. So kann beispielsweise mittels der dort erklärten “Empfindlichkeitsanalyse” die zur Beantwortung einer konkreten Benutzeranfrage relevanteste Informationsquelle identifiziert werden, d.h. diejenige Beobachtung einer Aktion, die die Auswahl einer bestimmten Hypothese am stärksten beeinflusste.

Zusätzlich wird die Klassifikation der zugehörigen Situation im entsprechenden Entscheidungsbaum durch Verfolgen des Pfades von der Wurzel bis zum diese Situation enthaltenden Blatt verbalisiert.

Beispiel 6.6.5 Angenommen, in obigem Beispiel sei die zur Hypothesenstärke (6.53) führende Beobachtung als relevant identifiziert worden. Eine Erklärung für die Entscheidung zugunsten von `Read_delete_msgs` wäre dann

“Die Hypothese `Read_delete_msgs` wurde ausgewählt, weil Sie diesen Plan *immer* verfolgt haben, wenn Sie eine Nachricht Ihres Chefs gelesen haben.”

Die Tatsache, daß beim Aufbau der Entscheidungsbäume auf eine minimale Anzahl notwendiger Tests von Attributwerten geachtet wird, erlaubt umgekehrt bei der Generierung einer Erklärung ebenfalls den Verzicht auf irrelevante Details, in diesem Fall etwa die Länge der entsprechenden Nachricht. Diese Abstraktion erhöht die

Transparenz der im Benutzermodell enthaltenen Information bzgl. der Annahmen des Systems über das typische Verhalten des Benutzers und kann so einerseits die Akzeptanz der getroffenen Entscheidungen erhöhen, andererseits Ansatzpunkte für eine “manuelle” Korrektur dieses Modells durch den Benutzer liefern.

Anmerkung: Gerade im Hinblick auf diese Wartung des Benutzermodells kann es wichtig sein, neben den Gründen für eine bestimmte Auswahl auch Rechtfertigungen für das Verwerfen von Alternativen und ähnliche Aspekte der Entscheidungsfindung anzufordern (siehe dazu auch [Bauer, 1996c]).

6.6.4 Verwandte Arbeiten

Techniken des maschinellen Lernens werden unter anderem auch für die in [Kozierok und Maes, 1993; Maes und Kozierok, 1993; Maes, 1994] beschriebenen Interface-Agenten angewandt. Hier ist das Ziel, Situationen und die jeweiligen Benutzerreaktionen darauf zu lernen. Situationen werden mittels einer vorgegebenen Menge von Attributen charakterisiert. Die Modellierung des Verhaltens des Benutzers beschränkt sich auf eine einzige Aktion.

Wann immer der Benutzer eines Anwendungssystems – eine Beispieldomäne ist ebenfalls ein email-System – eine neue Aktion ausführt, werden die entsprechenden Attributwerte und diese Aktion in eine Datenbasis eingetragen. Im Unterschied zu den in Abschnitt 6.6.2 vorgestellten *induktiven* Lernverfahren werden diese gesammelten Informationen nicht weiterverarbeitet. Die hier zur Anwendung kommende Technik des *memory-based reasoning* [Stanfill und Waltz, 1986] benutzt vielmehr diese Rohdaten, um beim Auftreten einer neuen Situation in der Datenbasis nach möglichst ähnlichen Einträgen zu suchen. Aus demjenigen mit der besten Übereinstimmung wird die damalige Benutzeraktion extrahiert und in Abhängigkeit vom Grad der Ähnlichkeit beider Situationen dem Benutzer entweder zur Ausführung angeboten oder automatisch durchgeführt.

Ein Nachteil dieses Lernverfahrens, das speziell für die Implementierung auf Hochleistungsrechnern mit Parallelarchitektur entwickelt wurde, besteht in der hohen Komplexität der Berechnungen, die zum Auffinden eines passenden Kandidaten durchgeführt werden müssen. Dabei ist jeweils die gesamte Datenbasis zu untersuchen.

Weiterhin ist festzustellen, daß eine Rechtfertigung für die Auswahl einer bestimmten Aktion als Hilfsangebot an den Benutzer lediglich durch Präsentation des entsprechenden Eintrags in der Datenbasis gegeben werden kann. Dies hat den Nachteil, daß der Benutzer mit einer Fülle konkreter Attributwerte – nämlich der Beschreibung einer früheren Situation, in der er sich ebenso verhielt – konfrontiert wird, von denen gegebenenfalls viele irrelevant für seine damalige Reaktion waren. Während ein induktives Verfahren viele solcher Details beim Aufbau eines Entscheidungsbau-
maes “ignoriert” und somit die zugrundeliegenden Strukturen deutlich hervorgehoben hätte, unterstützt die ausschließliche Verwendung der Rohdaten solche Einsichten in das interne Modell des System nicht.

Die Erkennung wiederkehrender Situationen ist ebenfalls das Ziel des in [Elzer *et al.*, 1994] beschriebenen Ansatzes. Dabei geht es um die Erkennung sogenannter “Attributwerte-Präferenzen” in Beratungsdialogen. Diese sollen die Bevorzugung gewisser Werte oder Eigenschaften der durch eine Aktion betroffenen Objekte repräsentieren. Ein Beispiel in der untersuchten Domäne der Beratung von Studenten bei der Studienplanung ist etwa die Bevorzugung bestimmter Dozenten oder Anfangszeiten der zu belegenden Kurse.

Wesentliches Merkmal ist die Ausnutzung der “kollaborativen Natur von Beratungsdialogen”. Das heißt, es wird davon ausgegangen, daß der Dialogpartner seine Präferenzen bereitwillig mitteilt. Die daraus resultierenden Auswirkungen auf den zugrundeliegenden Erkennungsmechanismus – der beispielsweise explizit geäußerte Präferenzen stärker bewertet als indirekt abgeleitete – schränken die Anwendung dieses Verfahrens auf Anwendungen mit intendierter Beobachtung ein, da sie die Bereitschaft des beobachteten Agenten zur Zusammenarbeit voraussetzen. Eine weitere Einschränkung ergibt sich durch die Verwendung von Information über die aktuellen Gesprächsumstände einer Äußerung – beispielsweise als Ablehnung einer Alternative oder Bekräftigung einer Aussage – bei der Berechnung der *Stärke* einer Präferenz. Solche Information ist ausschließlich im natürlichsprachlichen Kontext zu finden, so daß eine Anwendung beispielsweise bei der Beobachtung eines Softwarebenutzers nicht möglich ist.

Kapitel 7

Anwendung in PHI und RAP

Dieses Kapitel beschreibt die Integration des vorgestellten Planerkennungsansatzes in die im Rahmen der DFKI-Projekte PHI (Planbasierte Hilfesysteme) und RAP (Reasoning about Plans) entwickelten Systeme. Handelt es sich dabei im Falle von PHI um ein intelligentes Hilfesystem für ein Email-System unter UNIX, so steht bei RAP die Entwicklung eines generischen Systems im Vordergrund, das dem Benutzer die flexible Konfiguration spezieller Planungssysteme unter Verwendung existierender Inferenzdienste ermöglicht. In die Zeit des PHI-Projektes fällt neben der in Kapitel 5 beschriebenen modallogischen Fundierung regelbasierter Ansätze die Entwicklung der grundlegenden Konzepte zur Planerkennung, wie sie in den ersten beiden Abschnitten von Kapitel 6 vorgestellt werden. Die Aktualisierung des Benutzermodells, die Untersuchung von Approximationsalgorithmen für die Dempster-Shafer Theorie sowie vor allem die Integration maschinellen Lernens in die Planerkennung bildeten einen Schwerpunkt im Gebiet der Planerkennung im Rahmen von RAP (siehe dazu die Abschnitte 6.3 bis 6.6).

Abschnitt 7.1 bietet zunächst einen Überblick über das Projekt PHI, dessen logische Basis LLP Gegenstand von 7.2 ist. Danach wird in Abschnitt 7.3 die Planerkennung in PHI genauer betrachtet, wobei die durch den speziellen Ansatz mit verzahntem Plangenerierer und -erkenner bedingten Besonderheiten im Vordergrund stehen. Den Abschluß dieses Abschnittes bildet in 7.3.3 ein konkretes Anwendungsbeispiel.

7.1 Überblick über das Projekt PHI

Ziel des Projektes PHI war es, den Kern eines intelligenten, planbasierten Hilfesystems zu entwickeln, das *vollständig logikbasiert* ist und sowohl einen *Plangenerierer* als auch einen *Planerkenner* umfaßt [Bauer *et al.*, 1991; Bauer *et al.*, 1993]. Diese beiden Komponenten arbeiten in zwei sogenannten *Verzahnungsmodi* zusammen (siehe dazu auch Abbildung 7.1).

Im *ersten Verzahnungsmodus* produziert der Plangenerierer eine Menge abstrakter Pläne, die anschließend als Hypothesenmenge für den Planerkenner dient. Dessen Auf-

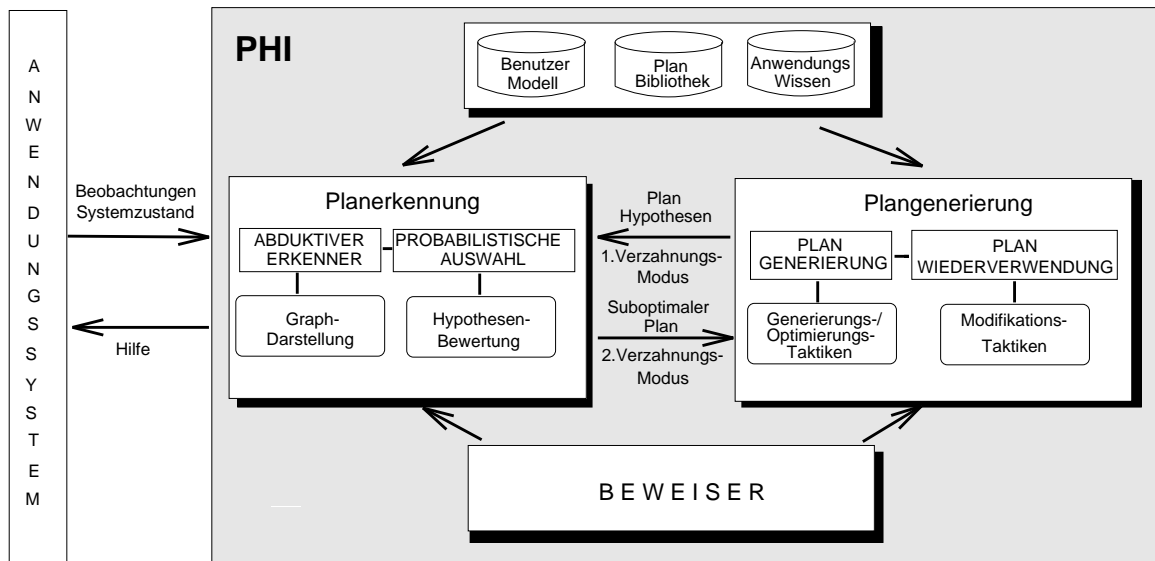


Abbildung 7.1: Die Gesamtarchitektur von PHI.

gabe ist es, den tatsächlich vom Benutzer eines Anwendungssystems – im konkreten Fall wurde email unter UNIX als Domäne betrachtet – verfolgten Plan zu identifizieren und auf der Basis des Erkennungsergebnisses Hilfeleistungen wie semantische Planvervollständigung anzubieten.

Der *zweite Verzahnungsmodus* geht noch darüber hinaus, indem hier suboptimales Benutzerverhalten erkannt und gegebenenfalls ein optimaler Plan für das aktuelle Ziel des Benutzers generiert und anschließend automatisch ausgeführt wird (siehe auch [Dengler, 1994]).

Die Eingabe für den Plangenerierer ist eine Menge von *Planspezifikationen*, spezieller LLP-Formeln, die die aktuellen Planungsaufgaben beschreiben. Auf die exakte Form der Planspezifikationen wird in Abschnitt 7.2 eingegangen. Jede dieser Spezifikationen wird zunächst an die *Wiederverwendungskomponente* übergeben (siehe [Koehler, 1994]). Diese versucht, in einer Planbibliothek ein bereits gelöstes ähnliches Problem zu finden und dessen Lösung wiederzuverwenden und gegebenenfalls zu modifizieren. Wird kein erfolgversprechender Kandidat gefunden, wird der *deduktive Plangenerierer* mit der aktuellen Planspezifikation aktiviert.

Die Kandidatensuche der Wiederverwendungskomponente arbeitet dabei auf einer Planbibliothek mit einem hybriden Repräsentationsformalismus, der Aspekte terminologischer Logiken und der Logik LLP miteinander verknüpft. Ein Bibliothekseintrag besitzt einen *Index*, der aus einer Planspezifikation durch Anwendung eines Kodierungsschemas gewonnen wurde, und beinhaltet weiterhin die tatsächliche Planspezifikation, den daraus erzeugten Plan sowie weitere Information aus dem Generierungsprozeß. Aufgrund der Indizes können Subsumptionsbeziehungen zwischen verschiedenen Einträgen berechnet werden.

Ein neues Planungsproblem, gegeben durch eine Planspezifikation, wird nun zu-

nächst mit demselben Kodierungsschema verarbeitet, und der entstehende Index wird gemäß dem Vorgehen in terminologischen Logiken in der Taxonomie der aktuellen Planbibliothek klassifiziert. Dabei können aufgrund der errechneten Subsumptionsbeziehungen Wiederverwendungskandidaten gefunden werden. Da die Kodierung in der terminologischen Logik lediglich eine approximative Repräsentation der ursprünglichen Spezifikationsformel darstellt, muß die tatsächliche Wiederverwendbarkeit eines Kandidaten noch formal bewiesen werden. Aufgrund dieses Beweises kann entschieden werden, ob der gefundene Plan verworfen werden muß, direkt wiederverwendet werden kann oder modifiziert werden muß. Im ersten Fall wird die Planspezifikation dem deduktiven Plangenerierer übergeben, im letzten Fall erhält man einen teilinstanziierten Plan, der noch "Lücken" in Form von Planmetavariablen aufweist, die durch entsprechende Aufrufe des deduktiven Plangenerierers instantiiert werden.

Dieser wiederum führt einen formalen Beweis der übergebenen Planspezifikationsformel, der als Seiteneffekt eine in dieser Formel enthaltene Metavariablen instantiiert. Wird der Beweis erfolgreich abgeschlossen, so stellt diese Instantiierung zusammen mit den zugehörigen Vorbedingungen den generierten Plan dar. Dieser ist also selbst wieder eine Formel der Logik LLP und kann als solche eine Reihe von *Freiheitsgraden* enthalten wie

- freie Variablen,
- temporale Abstraktionen und
- Disjunktionen.

Weiterhin können Pläne neben konkreten auch abstrakte Kommandos enthalten. Der deduktive Beweis der Planspezifikation in einem Sequenzenkalkül wird durch eine Reihe von *Taktiken* gesteuert, die in Abhängigkeit von der syntaktischen Form der zu beweisenden Formeln eine zielgerichtete Vorgehensweise erlauben und zu erheblich kleineren Beweisbäumen führen als dies bei konventionellen Beweisverfahren der Fall ist.

Die Verwendung der logischen Basis LLP in Kombination mit diesen Taktiken, die mit Hilfe des Systems IGLOO [Feibel, 1994; Feibel, 1995] entwickelt werden können, in allen Komponenten von PHI, erlaubt es dem System, ebenso effizient zu arbeiten wie herkömmliche, nicht-deduktive Planer, bietet dabei aber die Vorteile, daß

- die erzeugten Pläne *beweisbar korrekt* bzgl. ihrer Spezifikation sind und
- alle Prozesse innerhalb des Gesamtsystems (Plangenerierung und Planerkennung) eine *formale Semantik* besitzen und somit wohldefiniert sind.

7.2 Die Logik LLP

Ziel dieses Abschnitts ist die Einführung der Logik LLP (Logical Language for Planning), die die gemeinsame Grundlage aller Komponenten des PHI-Systems darstellt.

Es handelt sich dabei um eine sortierte, modale, intervallbasierte Temporallogik, die sowohl Aspekte temporaler Programmlogiken als auch der sogenannten *Choppy Logic* (siehe [Rosner und Pnueli, 1986]) beinhaltet. Eine ähnliche Logik wurde auch in [Bauer, 1992a; Bauer, 1992b] beschrieben. Für eine detaillierte Einführung in die grundlegenden Konzepte der Logik sei auf [Biundo *et al.*, 1992] verwiesen.

7.2.1 Syntax

Gegeben seien eine Menge S von Sortensymbolen und eine bezüglich S sortierte Signatur $\Sigma = \Sigma^F \cup \Sigma^P$, wobei Σ^F eine Signatur von Funktionssymbolen und Σ^P eine Signatur von Prädikatsymbolen ist.

Definition 7.2.1 (Stelligkeit)

S^* bezeichne die Menge aller endlichen Folgen von Sortensymbolen aus S . Die *Stelligkeit eines Funktionssymbols* $f \in \Sigma^F$ ist eine Folge $arity(f) = \omega s$ mit $\omega \in S^*$ und $s \in S$. ω bezeichnet die Sorten der Argumente von f , während s die Zielsorte ist. Die *Stelligkeit eines Prädikatsymbols* $p \in \Sigma^P$ ist eine Folge $arity(p) = \omega \in S^*$.

Im Gegensatz zu den meisten “klassischen” Logiken müssen in LLP zwei verschiedene Arten von Variablen unterschieden werden.

Definition 7.2.2 (Variablen)

Die Menge V der Variablen ist gegeben durch die Vereinigung $V = \cup_{s \in S} V_s$ aller Variablen der verschiedenen Sorten aus S . Dabei gilt für jede Sorte $s \in S$:

$$V_s = V_s^g \cup V_s^l.$$

V_s^g ist die Menge der *globalen Variablen* der Sorte s , während V_s^l die Menge der *lokalen Variablen* der Sorte s bezeichnet. V^g und V^l bezeichnen die Mengen aller globalen und lokalen Variablen aller Sorten.

Informal betrachtet, besteht zwischen beiden folgender Unterschied: Während globale Variablen dem “herkömmlichen” Variablenbegriff entsprechen, d.h. quantifiziert und *einmal* gebunden werden können, kann eine lokale Variable *nicht* in Verbindung mit einem Quantor auftreten und zu jedem Zeitpunkt einen anderen Wert annehmen. Diese entsprechen somit eher Variablen, wie sie aus imperativen Programmiersprachen bekannt sind. Der genaue Unterschied zwischen lokalen und globalen Variablen wird bei der Betrachtung der Interpretation von Termen deutlich.

Definition 7.2.3 (Terme)

Die Menge $T(\Sigma, s)$ der *Terme* der Sorte s über der Signatur Σ ist die kleinste Menge, für die gilt

- $V_s \subseteq T(\Sigma, s)$ und

- wenn $t_1 \in T(\Sigma, s_1), \dots, t_n \in T(\Sigma, s_n)$ Terme der Sorten s_1, \dots, s_n sind und $f \in \Sigma^F$ ein Funktionssymbol der Stelligkeit $s_1 \dots s_n s$, dann ist $f(t_1, \dots, t_n) \in T(\Sigma, s)$ ein Term der Sorte s .

Definition 7.2.4 (Formeln)

Die Menge $WFF(\Sigma)$ der *Formeln* über Σ ist die kleinste Menge, für die gilt:

1. $T \in WFF(\Sigma)$.
2. $p(t_1, \dots, t_n) \in WFF(\Sigma)$, falls $t_i \in T(\Sigma, s_i)$ für $i = 1, \dots, n$, $p \in \Sigma^F$ und $arity(p) = s_1 \dots s_n$.
3. $t_1 = t_2 \in WFF(\Sigma)$, falls $t_1, t_2 \in T(\Sigma, s)$ für ein $s \in S$.
4. $\neg \varphi \in WFF(\Sigma)$, falls $\varphi \in WFF(\Sigma)$.
5. $\varphi \wedge \psi \in WFF(\Sigma)$, falls $\varphi, \psi \in WFF(\Sigma)$.
6. $\forall x : s. \varphi \in WFF(\Sigma)$, falls $\varphi \in WFF(\Sigma)$ und $x \in V_s^g$.
7. $\circ \varphi \in WFF(\Sigma)$, falls $\varphi \in WFF(\Sigma)$.
8. $\diamond \varphi \in WFF(\Sigma)$, falls $\varphi \in WFF(\Sigma)$.
9. $(\varphi ; \psi) \in WFF(\Sigma)$, falls $\varphi, \psi \in WFF(\Sigma)$.
10. $x := t \in WFF(\Sigma)$, falls $x \in V_s^l$ und $t \in T(\Sigma, s)$.

Anmerkungen:

1. Im folgenden wird meist statt $T(\Sigma, s)$ und $WFF(\Sigma)$ einfach $T(s)$ und WFF geschrieben.
2. Zusätzlich zu den in Definition 7.2.4 angegebenen Konnektoren werden \vee, \rightarrow und \leftrightarrow mit der üblichen Interpretation ebenso als Abkürzung in den Formeln verwendet wie der Existenzquantor \exists .
3. Während die Punkte 1.–6. der Syntax einer herkömmlichen sortierten Logik erster Stufe entsprechen, führen die Punkte 7.–9. die modallogischen Konzepte und 10. einen programmlogischen Anteil in die Sprache ein. Im einzelnen gilt:
 - \circ ist der sog. *next*-Operator,
 - \diamond wird als *sometimes*-Operator bezeichnet, und
 - $;$ ist der *chop*-Operator.

Zusätzlich wird der zu \diamond duale Operator \square (*always*) verwendet.

4. Punkt 10. aus Definition 7.2.4 beschreibt die sogenannte *Zuweisung* eines Wertes an eine lokale Variable.
5. Um später komplexe Pläne in der Sprache LLP repräsentieren zu können, werden weitere abgeleitete Operatoren eingeführt, mit deren Hilfe programmiersprachenähnliche Konstrukte wie Verzweigungen und Schleifen dargestellt werden können. Dabei bezeichnen im folgenden φ und ψ Formeln im Sinne von Definition 7.2.4, während α eine Formel ohne Modaloperator ist. Dann gilt:

$$\mathbf{if} \ \alpha \ \mathbf{then} \ \varphi \ \mathbf{else} \ \psi \Leftrightarrow (\alpha \rightarrow \varphi) \wedge (\neg\alpha \rightarrow \psi)$$

sowie

$$(\mathbf{while} \ \alpha \ \mathbf{do} \ \varphi \ \mathbf{od} ; \psi) = \mathbf{if} \ \alpha \ \mathbf{then} \ (\varphi ; (\mathbf{while} \ \alpha \ \mathbf{do} \ \varphi \ \mathbf{od} ; \psi)) \ \mathbf{else} \ \psi.$$

6. Die Sprache enthält außerdem ein ausgezeichnetes einstelliges Prädikat ex , das als Argument einen Term der Sorte *command* erhält und die Ausführung eines Kommandos zu einem bestimmten Zeitpunkt beschreibt.

7.2.2 Semantik

Der zentrale Begriff der LLP-Semantik ist das *Intervall*, das als eine nichtleere Folge von *Zuständen* den Aspekt der Zeit repräsentiert. Da diese Logik die (sortierte) Prädikatenlogik erster Stufe vollständig umfaßt, wird zunächst deren grundlegendes Konzept eingeführt (siehe dazu auch [Enderton, 1972, Kapitel2]).

Definition 7.2.5 (Σ -Struktur)

Zu einer Signatur Σ ist das Paar (D, I) eine sogenannte Σ -Struktur. $D = (D_s)_{s \in S}$ heißt der *Grundbereich*, und $I = (I(f))_{f \in \Sigma}$ ist eine Familie von Abbildungen, die den Symbolen aus Σ Funktionen und Prädikate über D zuordnen.

Definition 7.2.6 (Zustand)

Ein *Zustand* ist ein Paar (σ^1, σ^2) mit

- $\sigma^1 : V_s^l \rightarrow D_s$ ist eine Belegungsfunktion für alle lokalen Variablen.
- $\sigma^2 \in T(\Sigma, \mathit{command})$ ist die sogenannte *Kontrollkomponente*.

Die Kontrollkomponente beinhaltet das aktuell ausgeführte Kommando. Dabei wird vorausgesetzt, daß zu jedem Zeitpunkt *genau ein* Kommando ausgeführt wird. Die syntaktische Entsprechung ist eine atomare Formel $ex(c)$ mit $c \in T(\Sigma, \mathit{command})$, die in diesem Zustand gültig ist, falls $\sigma^2 = c$ gilt (siehe dazu auch Definition 7.2.11). Einzige Ausnahme davon sind Formeln der Form $x := t$, wobei $x \in V^l$ eine lokale Variable und t ein Term ist. Diese *Zuweisung* ist das einzige Kommando, das nicht mittels des Prädikates ex dargestellt wird.

Definition 7.2.7 (Intervall, Länge, Komposition)

Ein *Intervall* ist eine nichtleere Folge $\sigma = \langle \sigma_0, \sigma_1, \dots \rangle$ von Zuständen σ_i . Über Intervallen sind folgende Operationen definiert: Die *Länge* eines Intervalls σ ist gegeben durch

$$|\sigma| = \begin{cases} n, & \text{falls } \sigma = \langle \sigma_0, \dots, \sigma_n \rangle \\ \infty, & \text{falls } \sigma \text{ unendlich} \end{cases}$$

Die *Komposition* zweier Intervalle σ, σ' ist gegeben durch

$$\sigma \circ \sigma' = \begin{cases} \sigma, & \text{falls } \sigma \text{ unendlich} \\ \langle \sigma_0, \dots, \sigma_n, \dots \rangle, & \text{falls } \sigma = \langle \sigma_0, \dots, \sigma_n \rangle \text{ und } \sigma' = \langle \sigma_n, \dots \rangle \end{cases}$$

Die Menge aller Intervalle wird mit W_0 bezeichnet.

Anmerkungen:

1. Die Länge eines Intervalls bezeichnet die Anzahl der *Zustandsübergänge*, ist also identisch mit der um eins verringerten Anzahl der Zustände im Intervall.
2. Die Komposition zweier Intervalle ist nur dann definiert, wenn das erste der beiden unendlich lang ist (die Komposition ist dann die identische Abbildung) oder beide Intervalle um einen Zustand "überlappen", d.h. wenn der letzte Zustand des ersten Intervalls mit dem ersten des zweiten Intervalls identisch ist.

Intervalle spielen in der Logik LLP die Rolle *möglicher Welten* in der Kripke-Semantik einer Modallogik (vergleiche dazu z.B. [Chellas, 1980]). Daher muß eine *Erreichbarkeitsrelation* zwischen diesen Welten angegeben werden.

Definition 7.2.8 (Erreichbarkeit)

Die *unmittelbare Erreichbarkeit* ist eine Relation R mit $\sigma R \sigma'$, falls $\sigma = \langle \sigma_0, \sigma_1, \dots \rangle$ und $\sigma' = \langle \sigma_1, \dots \rangle$ das Teilintervall ist, das man aus σ durch Streichen des ersten Zustandes σ_0 erhält. Die reflexive, transitive Hülle von R wird mit R^* bezeichnet.

Definition 7.2.9 (Σ -Interpretation)

Sei die Signatur Σ mit einer Σ -Struktur (D, I) gegeben. Eine Σ -*Interpretation* ist dann ein Tupel $\mathcal{I}_\Sigma = \langle W, R, \circ, D, I, \beta \rangle$, wobei

- $W \subseteq W_0$ eine nichtleere Menge von Intervallen ist, die durch die unmittelbare Erreichbarkeitsrelation R miteinander verknüpft sind,
- $\beta : V^g \rightarrow D$ eine Belegungsfunktion der globalen Variablen ist und
- \circ, D, I wie bisher die Kompositionsoption sowie die beiden Komponenten einer Σ -Struktur darstellen.

Auf der Basis dieser Definition ist es nun möglich, die Interpretation von Termen und Formeln und insbesondere deren Gültigkeit anzugeben.

Definition 7.2.10 (Interpretation von Termen)

Für eine Σ -Interpretation \mathcal{I} , bestehend aus einem Rahmen (W, R, \circ) , einer Σ -Struktur (D, I) und einer Belegung β ist der Wert eines Terms $t \in \mathcal{T}_\Sigma$ in einem Intervall $\sigma \in W$ definiert gemäß:

- $\mathcal{I}_\Sigma^g(x) = \beta(x)$ für jedes $x \in V^g$
- $\mathcal{I}_\Sigma^g(a) = \sigma_0^1(a)$ für jedes $a \in V^l$.

Die Erweiterung dieser Interpretation auf Funktionsausdrücke geschieht auf die übliche Weise.

Anmerkung: Kommandotermine, d.h. Terme der Sorte *command*, werden nicht evaluiert im Sinne dieser Definition, d.h. für alle $c \in T(\Sigma, \text{command})$ gilt $\mathcal{I}_\Sigma^g(c) = c$.

Definition 7.2.11 (Gültigkeit von Formeln)

Die Gültigkeit einer Formel $\phi \in WFF$ unter einer Σ -Interpretation \mathcal{I} in einem Intervall $\sigma \in W$ (kurz: $\sigma \models_{\mathcal{I}} \phi$) ist wie folgt definiert:

1. $\sigma \models_{\mathcal{I}} \top$
2. $\sigma \models_{\mathcal{I}} ex(t)$ gdw. $\mathcal{I}_\Sigma(t) = \sigma_0^2$
3. $\sigma \models_{\mathcal{I}} \bigcirc \phi$ gdw. $\sigma' \models_{\mathcal{I}} \phi$ für alle σ' mit $\sigma R \sigma'$
4. $\sigma \models_{\mathcal{I}} \Box \phi$ gdw. $\sigma' \models_{\mathcal{I}} \phi$ für alle σ' mit $\sigma R^* \sigma'$
5. $\sigma \models_{\mathcal{I}} \phi; \psi$ gdw. es gibt σ', σ'' mit $\sigma = \sigma' \circ \sigma''$, σ' endlich, $\sigma' \models_{\mathcal{I}} \phi$ und $\sigma'' \models_{\mathcal{I}} \psi$
6. $\sigma \models_{\mathcal{I}} \psi$ ist wie üblich definiert für $\psi = p(t_1, \dots, t_n)$, $\psi = (t_1 = t_2)$, $\psi = \neg \phi$, $\psi = \phi_1 \wedge \phi_2$, $\psi = \forall x \phi$.

Anmerkungen:

1. Wie Terme werden auch atomare Formeln jeweils über dem ersten Zustand des Intervalls gedeutet.
2. Der \bigcirc Operator repräsentiert das sogenannte *weak next*, d.h. die Existenz des nächsten Zustands wird nicht ausdrücklich vorausgesetzt.
3. Der Chop-Operator $;$ ist die syntaktische Entsprechung der Komposition \circ zweier Intervalle.

Definition 7.2.12 (Modell)

Eine Σ -Interpretation $\mathcal{I} = (W, R, \circ, D, I, \beta)$ ist nun *Modell* einer Formel ϕ ($\models_{\mathcal{I}} \phi$) gdw. $\sigma \models_{\mathcal{I}} \phi$ für jedes $\sigma \in W$. ϕ ist *allgemeingültig* gdw. $\models_{\mathcal{I}}$ für alle \mathcal{I} .

7.3 Planerkennung in PHI

Die Gesamtarchitektur des Planerkennters von PHI und dessen Interaktion mit dem Gesamtsystem sind in Abbildung 7.2 dargestellt (siehe auch [Bauer und Paul, 1993]). Der eigentliche Erkenner besteht aus dem sogenannten *abduktiven Planerkenner*, dessen Rolle noch erläutert wird, und dem *Auswahlmodul*, das eine prototypische Implementierung der in Kapitel 6 vorgestellten Konzepte im Rahmen von PHI darstellt.

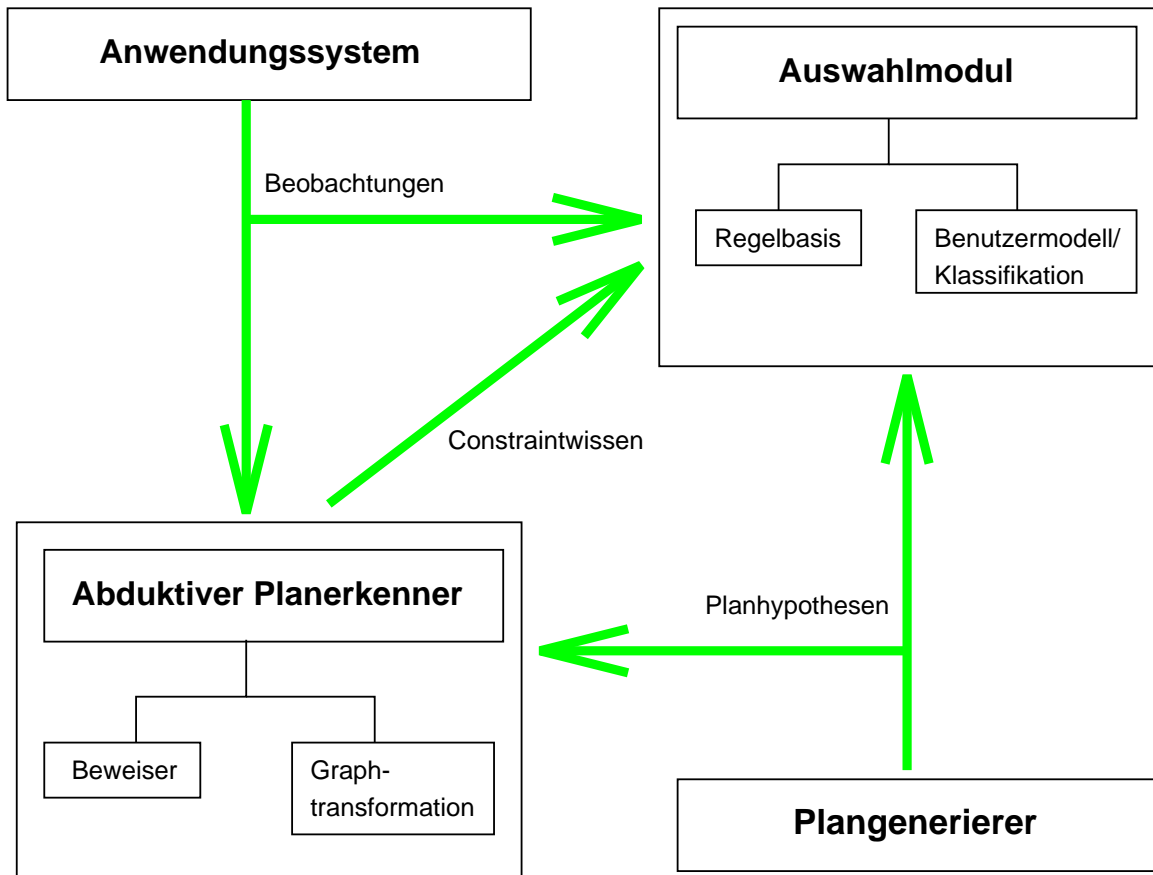


Abbildung 7.2: Die Architektur des Planerkennters in PHI.

7.3.1 Der abduktive Erkenner

Die Kennzeichnung des eigentlichen Planerkennters als *abduktiver* Mechanismus ist eine Folge seiner Arbeitsweise, die ausgehend von Beobachtungen (im konkreten Fall email-Kommandos) Planhypothesen sucht, die als *Erklärung* für diese dienen. Dieses Schließen von "Symptomen" auf die "Ursachen" ist charakteristisch für abduktives Vorgehen.¹ Dabei macht die spezielle Logik LLP, in der sowohl die Planhypothe-

¹Für eine Einführung in das abduktive Schließen sei an dieser Stelle auf [Paul, 1993] verwiesen.

sen als auch die Vorbedingungen und die Beobachtungen $ex(\langle \textit{kommendo} \rangle)$ formuliert sind, eine Verallgemeinerung des klassischen Abduktionsbegriffes notwendig, der zur Definition der *temporalen Abduktion* mit einem schwächeren Erklärungs begriff führt.

Während nämlich eine klassische abduktive Erklärung für eine Beobachtung lediglich durch Bildung von Grundinstanzen aus einer Menge sogenannter *Abduzibler* gewonnen werden darf, sind in der temporalen Variante darüberhinaus auch sogenannte *Konkretisierungsoperationen* erlaubt, die beispielsweise temporale Abstraktionen aus Planhypothesen entfernen und diese somit – ähnlich der Instanzenbildung – konkretisieren.

Basis für diesen abduktiven Erkennungsprozeß ist eine *äquivalenzerhaltende Transformation* der Planformeln in gerichtete Graphen. Diese erlauben eine effizientere Bearbeitung der Planhypothesen, da die aktuellen Knoten des Graphen, die für die nächsten erwarteten Aktionen stehen, identifiziert werden können, was bei direkter Verwendung der *Planformeln* aufwendige Berechnungen notwendig machen würde. Die Eigenschaft dieser Transformation, logisch äquivalente Planformeln in identische Graphen zu überführen und die Existenz einer “Rückübertragung” der Graphen in die Logik erlaubt die Beibehaltung der formalen Semantik sowohl der einzelnen Pläne, als auch des gesamten Erkennungsprozesses auf der Basis von LLP.

Die Eingliederung der Planerkennung in den Gesamtprozeß ist wie folgt:

1. Der Benutzer startet seine Interaktion mit dem Anwendungssystem. Konkret bedeutet dies, daß das Mail-Programm aufgerufen wird.
2. Der Benutzer wird identifiziert, und aus dem zugehörigen Benutzermodell wird eine dort abgelegte numerische Bewertung der Menge der vorhandenen Planspezifikationen abgefragt.
3. Aufgrund dieser numerischen Information und der Vorgabe einer Maximalanzahl werden die am besten bewerteten Spezifikationen zur Weiterverarbeitung durch den Plangenerierer ausgewählt. Diese *Selektionsphase* ist durch das Bestreben motiviert, die Anzahl der aufwendigen Generierungsschritte zu minimieren. Deshalb wird hier nur eine begrenzte Anzahl aller vorhandenen Planspezifikationen an den Generierer übergeben, wobei die Information aus dem Benutzermodell dazu dient, diejenigen auszuwählen, die in der Vergangenheit das Verhalten des aktuellen Benutzers am besten beschrieben haben.
4. Der Plangenerierer erzeugt aus diesen Spezifikationen eine Menge von Planhypothesen (vergleiche Abschnitt 7.1).
5. Der eigentliche Zyklus aus Benutzerinteraktion und Planerkennung beginnt.

Erster Schritt der Planerkennung ist die Transformation aller vom Plangenerierer gelieferten Planhypothesen und die Bestimmung aller Knoten in den entstehenden Graphen, die als Kandidat für die erste erwartete Aktion in Frage kommen. Wird nun vom Anwendungssystem eine Benutzeraktion a gemeldet – im konkreten Fall ein

email-Kommando – so werden zunächst alle Hypothesen bestimmt, die entweder a explizit vorgesehen haben oder zumindest mit dieser Beobachtung kompatibel sind in dem Sinne, daß ein Auftreten von a nicht explizit ausgeschlossen war. Alle anderen Hypothesen werden verworfen.

Der Test der zugehörigen Constraints erfolgt, indem die aktuelle Parameterbindung von a mit bereits existierenden Variablenbindungen der einzelnen Hypothesen verglichen und diese gegebenenfalls konsistent erweitert werden. Ist dies nicht möglich, müssen die entsprechenden Hypothesen abgelehnt werden. Weiterhin ist es notwendig, bestimmte Bedingungen innerhalb der Domäne zu überprüfen, die den aktuellen Zustand der Welt betreffen. Typische Beispiel dafür sind

$$\text{open_flag}(\text{sys_mbox}) = 1$$

oder

$$\text{delete_flag}(\text{msg}(3, \text{sys_mbox})) = 0,$$

die besagen, daß eine bestimmte System-Mailbox geöffnet sein muß und die dritte Nachricht darin nicht gelöscht sein darf. Die Gültigkeit dieser Aussagen wird durch direkte Anfragen an das Anwendungssystem bestimmt, die durch eine Prozeßkommunikation realisiert ist. Auch hier kann die Verletzung solcher Bedingungen zur Entfernung einer Hypothese aus dem Suchraum führen.

Das Ergebnis eines solchen Erkennungsschrittes ist eine Teilmenge der ursprünglichen Planhypothesen, die mit Hilfe der Beobachtung a und der Überprüfung der zugehörigen Constraints konkretisiert wurden, indem

- freie Variablen gebunden und
- temporale Abstraktionen oder Disjunktionen entfernt wurden.

Die Menge der mit allen bisherigen Beobachtungen konsistenten Hypothesen sowie die Information darüber, welche dieser Hypothesen fortgeschrieben werden konnten in dem Sinne, daß die Aktion a in ihnen tatsächlich erwartet wurde und alle Constraints erfüllt waren, wird an das Auswahlmodul übergeben. Dieses berechnet auf der Basis der aktuellen Beobachtung und der vom abduktiven Erkennen zur Verfügung gestellten Information eine neue Hypothesenbewertung (siehe unten). Danach wird die nächste Benutzereingabe erwartet.

Bleibt nur *eine* konsistente Planhypothese übrig, so wird diese dem Benutzer zur automatischen Abarbeitung angeboten. Werden hingegen *alle* Planhypothesen verworfen, so wird ein neuer Generierungs- und Erkennungszyklus gestartet, d.h. es werden wiederum Planspezifikationen ausgewählt und neue Hypothesen generiert.

7.3.2 Der Auswahlmodul

In diesem Abschnitt wird die Arbeitsweise des auf den Konzepten von Kapitel 6 aufbauenden Auswahlmoduls im Zusammenspiel mit den übrigen Systemkomponenten

beschrieben. Einen zentralen Punkt stellt dabei die Initialisierung des Hypothesenraumes dar, die in Abschnitt 7.3.2.1 erläutert wird. Abschnitt 7.3.2.2 beinhaltet eine Beschreibung der Rolle des Auswahlmoduls im Gesamtsystem.

7.3.2.1 Die Initialisierungsphase

Wie bereits mehrfach erwähnt, wird eine numerische Bewertung der Elemente des Hypothesenraumes in Form eines (quantitativen) Benutzermodells vorausgesetzt, mit dessen Hilfe eine initiale Basiswahrscheinlichkeit für die Hypothesen erstellt wird. Dies widerspricht jedoch dem Vorgehen innerhalb des PHI-Systems. Da die einzelnen Planhypothesen *zur Laufzeit des Hilfesystems* dynamisch generiert werden, können keinerlei statistische Daten über ihre relative Häufigkeit im Verhalten eines Benutzers vorliegen. Daher muß hier zu einem Hilfsmittel gegriffen werden.

In einer Wissensbasis hält das System eine Menge CF von LLP-Formeln, die sich in zwei disjunkte Gruppen einteilen lassen: $CF = CF_p \cup CF_g$. Dabei umfaßt CF_p eine Menge von *Planformeln*, während CF_g sogenannte *Zielformeln* beinhaltet. Erstere beschreiben Aktionssequenzen wie beispielsweise

```
sometimes ( ex(save(msg(x,y)));
            ex(delete(msg(x,y)));
            ex(quit(y)) ) .
```

Zielformeln weisen Ähnlichkeiten mit Planspezifikationen auf (siehe Abschnitt 7.2), hier fehlt lediglich die Planmetavariablen. Ein Beispiel dafür ist

```
(exists yb:
  (exists zb:
    (sometimes(
      (forall xb: (((sender(msg(xb,yb))=zb) &
                    (delete_flag(msg(xb,yb)) = 0) &
                    (open_flag(yb)=1))
                    ~~>
      ((read_flag(msg(xb,yb))=1)))))))) .
```

Da beide Beispiele direkt dem implementierten System entnommen sind, sind hier die logischen Zeichen wie \diamond durch ASCII-Ketten wie `sometimes` ersetzt. Während diese Planformel eine lineare Folge der drei Kommandos `save`, `delete` und `quit` mit den entsprechenden Argumenten beschreibt, bezeichnet die Zielformel das Ziel, irgendwann alle nicht gelöschten Nachrichten eines bestimmten Absenders `zb` in einer geöffneten Mailbox `yb` gelesen zu haben.

Die Intention hinter CF ist, eine Sammlung typischer Aktionsfolgen – kodiert in CF_p – und typischer Ziele innerhalb der Domäne – kodiert in CF_g – aufzustellen und zu testen, wie oft der Benutzer die jeweiligen Aktionsfolgen durchführt bzw. die entsprechenden Ziele verfolgt. Grundlage dafür sind die vom Benutzer in vorhergehenden

Sessions ausgeführten Aktionen und die dabei erkannten Pläne. Die vom Plangenerierer gelieferten Pläne werden dann bzgl. der Elemente von CF *klassifiziert*, d.h. für jeden Plan wird überprüft, welche der durch die Formeln in CF_p beschriebenen Aktionsfolgen er als Teilplan beinhaltet und welche der durch CF_g beschriebenen Ziele er erreicht. Daher werden die Elemente von CF auch als *Klassifikationskriterien* bezeichnet.

Da sowohl die Planhypothesen als auch deren Spezifikationen und die Elemente aus CF LLP-Formeln sind, können diese Tests wiederum durch formale, taktikgesteuerte Beweise durchgeführt werden. Für einen Plan p mit Spezifikation $spec(p)$ und zwei Klassifikationskriterien $cp \in CF_p$ und $cg \in CF_g$ müssen dazu die Implikationen

$$\begin{aligned} p &\rightarrow cp, \\ spec(p) &\rightarrow cg \end{aligned} \tag{7.1}$$

bewiesen werden.

Seien also eine Menge CF von Klassifikationskriterien k_1, \dots, k_l gegeben sowie eine numerische Bewertung $val : CF \rightarrow [0, 1]$ mit $\sum_{i=1}^l val(k_i) = 1$ und eine Menge \mathcal{P}_0 von Plänen mit den zugehörigen Planspezifikationen. Dann wird daraus eine Menge

$$CM = \{C_{i_1, \dots, i_n} \mid 1 \leq i_j \leq l\} \subseteq 2^{\mathcal{P}_0}$$

konstruiert mit

- $CM \ni C_{i_1, \dots, i_n} \neq \emptyset$
- Für alle $p \in C_{i_1, \dots, i_n}$: p erfüllt alle Kriterien k_{i_1}, \dots, k_{i_n} im Sinne von (7.1).
- Alle $C_{i_1, \dots, i_n} \in CM$ sind maximal, d.h. falls $p \notin C_{i_1, \dots, i_n}$, dann erfüllt p keines der Kriterien k_{i_1}, \dots, k_{i_n} .

Definition 7.3.1 (induzierte Hypothesenbewertung)

Die durch CF und \mathcal{P}_0 *induzierte Hypothesenbewertung* ist die Funktion $m : 2^{\mathcal{P}_0} \rightarrow [0, 1]$ mit

$$m(X) = \begin{cases} \frac{1}{K} \sum_{j=1}^n val(k_{i_j}), & X = C_{i_1, \dots, i_n} \in CM \\ 0, & \text{sonst} \end{cases}$$

mit K so, daß $\sum_{C \in CM} m(C) = 1$.

Anmerkungen:


1. m ist eine Basiswahrscheinlichkeit. Die Fokalelemente sind gerade die Elemente aus CM .
2. m stellt eine initiale Bewertung des Hypothesenraumes dar. Sie wird induziert, indem die numerischen Gewichte der einzelnen Klassifikationskriterien an die sie erfüllenden Teilmengen des Hypothesenraumes “vererbt” werden.

Anhand eines Beispiels soll das Vorgehen bei der Klassifikation veranschaulicht werden.

Beispiel 7.3.1 Seien $\mathcal{P}_0 = \{p_1, p_2, p_3\}$, $CF = \{k_1, k_2, k_3, k_4, k_5\}$ mit den Gewichten

$$val(X) = \begin{cases} 0.2, & X = k_1 \\ 0.3, & X = k_2 \\ 0.1, & X = k_3 \\ 0.2, & X = k_4 \\ 0.2, & X = k_5 \end{cases}$$

Das Ergebnis der Klassifikation sei durch folgenden Graphen gegeben:



Das bedeutet, daß beispielsweise p_1 die Kriterien k_1, k_3 und k_5 erfüllt und k_3 von p_1 und p_3 erfüllt wird. Daraus ergeben sich die folgenden Zuordnungen von Teilmengen von \mathcal{P}_0 zu den jeweiligen Kriterien k_i :

$$C_i = \begin{cases} \{p_1, p_2\}, & i = 1 \\ \{p_3\}, & i = 2 \\ \{p_1, p_3\}, & i = 3 \\ \emptyset, & i = 4 \\ \{p_1, p_2\}, & i = 5 \end{cases}$$

Es ist zu beobachten, daß k_4 von keinem der Pläne aus \mathcal{P}_0 erfüllt wird, und daß C_1 und C_5 identisch sind. Diese werden daher zu $C_{1,5}$ zusammengefaßt. Die Tatsache, daß C_4 leer ist und k_4 mit 0.2 bewertet war, bedingt, daß der Normierungsfaktor $K = 0.8$ ist. Somit ergibt sich folgende induzierte Hypothesenbewertung:

$$m(X) = \begin{cases} (val(k_1) + val(k_5))/0.8 = 0.5, & X = C_{1,5} = \{p_1, p_2\} \\ val(k_2)/0.8 = 0.375, & X = C_2 = \{p_3\} \\ val(k_3)/0.8 = 0.125, & X = C_3 = \{p_1, p_3\} \\ 0, & \text{sonst} \end{cases}$$

$\{p_1, p_2\}$ und $\{p_1, p_3\}$ repräsentieren somit auch abstrakte Pläne innerhalb der Planhierarchie über 2^{P_0} .

7.3.2.2 Kopplung mit dem abduktiven Planerkenner

Neben einer initialen Hypothesenbewertung wird außerdem eine Beobachtungsfunktion benötigt. Wie in Abschnitt 6.1.3.2 erläutert, kann diese aus den Plandekompensationen abgeleitet werden. Da ein Plan innerhalb von PHI lediglich aus *einer* LLP-Formel besteht, ist diese auch mit seiner Dekomposition identisch. Durch Parsen dieser Formel können alle in einem Plan auftretenden Aktionen extrahiert und somit die entsprechenden Beobachtungsregeln aufgestellt werden. Die Initialisierung der numerischen Gewichte wird gemäß der Beschreibung im vorigen Kapitel vorgenommen.

Auch die Constraints, die eine Aktion mit einer Planhypothese verbinden, sind nicht alle explizit gegeben. Zwar finden sich Bedingungen bzgl. bestimmter Aktionsparameter in den Vorbedingungen des Planes wieder, aber beispielsweise Aussagen über die *zeitliche Abfolge* der einzelnen Aktionen innerhalb eines Planes lassen sich nur durch eine Analyse der temporalen Struktur der entsprechenden Planformeln extrahieren. Da alle diese Bedingungen jedoch bereits vom abduktiven Planerkenner getestet werden, ist es nicht notwendig, alle vorhandenen Constraints explizit zu machen. Vielmehr genügt es, von diesem in jedem Schritt die Information darüber zu erhalten, welche der vorhandenen Planhypothesen p mit Hilfe der aktuell beobachteten Aktion a konkretisiert werden konnten und welche nicht. Für erstere gilt dann, daß $C_p(a)$ erfüllt sein muß, während bei letzteren mindestens eine Bedingung verletzt war.

Der Test auf Gültigkeit der Constraints $C_p(a)$ beschränkt sich somit im Auswahlmodul darauf festzustellen, ob p ein Element der vom abduktiven Planerkenner übermittelten Liste der erfolgreich fortgeschriebenen Planhypothesen ist. Aufgrund dieser Information können die für die partielle Regelanwendung notwendigen Modifikationen der Beobachtungsregeln berechnet werden (vergleiche Abschnitt 6.1.3.3).

Die Aufgabe des Auswahlmoduls im Gesamtsystem ist es, zu jedem Zeitpunkt die numerische Bewertung des Hypothesenraumes auf der Basis der neuen Benutzereingabe zu aktualisieren und gegebenenfalls die "beste" Planhypothese auszugeben, sobald ein bestimmtes Kriterium erfüllt ist. Zu diesem Zweck können verschiedene Selektionskriterien definiert werden. Beispiele dafür sind das Überschreiten eines bestimmten Schwellwertes durch die "pignistische" Wahrscheinlichkeit einer Hypothese oder der direkte Vergleich aller Belief-Werte.

Wird ein Plan auf diese Weise ausgewählt, so kann mit Hilfe der Klassifikationskriterien in CF_p festgestellt werden, ob er suboptimale Aktionsfolgen enthält. Ist dies der Fall, so wird der Plan (bzw. seine Spezifikation) nach Bestätigung durch den Benutzer dem deduktiven Plangenerierer übergeben, der einen nach bestimmten Kriterien optimalen Plan für das ursprünglich verfolgte Ziel erzeugt, der dann dem Benutzer zur automatischen Abarbeitung angeboten werden kann.

7.3.3 Ein konkretes Beispiel

Dieser Abschnitt beschreibt ein Beispiel der Arbeitsweise des PHI-Systems (siehe dazu auch [Bauer *et al.*, 1993]). Bevor die einzelnen Schritte genauer erläutert werden, soll zunächst das konkrete Szenario aus der email-Domäne vorgestellt werden.

The screenshot shows the PHI Prototype 2.0 interface. The main window is titled "Mail System". On the left, there are buttons for "Start", "New", "Proofs", "Help!", "Go on", and "Quit". The interface is divided into several panes:

- Mail System:** Shows "Allowed Commands: 'mail(<user>)', 'reset', 'logout'". The shell prompt is "Shell>> mail(spock)".
- Classification Formulas:** Lists four formulas:
 - Classification Formula a: 0.2, sometimes ex(save(msg(x,y))) ; ex(delete(msg(x,y))) ; ex(quit)
 - Classification Formula c: 0.1, sometimes ex(quit)
 - Classification Formula f: 0.1, sometimes ex(type(msg(x,y))) ; ex(delete(msg(x,y)))
 - Classification Formula b: 0.3, exists yb, zb : sometimes forall xb : (((sender(msg(xb,yb)) = zb) & ((delete_flag(msg(xb,yb)) = 0) & (open_flag(yb) = 1)))) ~-> sometimes (read_flag(msg(xb,yb)) = 1)
 - Classification Formula d: 0.2, exists yb, zb : sometimes forall xb : (((sender(msg(xb,yb)) = zb) & ((delete_flag(msg(xb,yb)) = 0) & (open_flag(yb) = 1)))) ~-> sometimes (delete_flag(msg(xb,yb)) = 1)
- Plan Recognition:** Shows a list of test results:
 - Current test for p4 and criterion a... ..failed
 - Current test for p4 and criterion c... ..failed
 - Current test for p4 and criterion f... ..failed
 - Current test for p4 and criterion b... ..succeeded
 - Current test for p4 and criterion d... ..failed
 - Current test for p4 and criterion e... ..failed
 - Current test for p2 and criterion a... ..succeeded
 - Current test for p2 and criterion c... ..succeeded
 - Current test for p2 and criterion f... ..succeeded
 - Current test for p2 and criterion b... ..failed
 - Current test for p2 and criterion d... ..failed
 - Current test for p2 and criterion e... ..failed
 - Current test for p3 and criterion a... ..failed
 - Current test for p3 and criterion c... ..succeeded
 - Current test for p3 and criterion f... ..succeeded
 - Current test for p3 and criterion b... ..failed
 - Current test for p3 and criterion d... ..failed
- Plan Generation:** Shows a sequence of actions:


```
ex(from(scotty, system_mbox)) & next (next false) ;
ex(folders(system_mbox)) & next (next false) ;
ex(type(x, system_mbox)) & next (next false) ;
ex(delete(x, system_mbox)) & next (next false) ; ex(quit(system_mbox))
```
- Plan Library:** Shows a hierarchical tree of plans:
 - top
 - p3 (shaded) and p4
 - p2 and p1
 - bottom

Abbildung 7.3: Die Oberfläche des PHI-Systems während der Klassifikationsphase.

Der aktuell beobachtete Benutzer Spock pflegt, innerhalb einer Session lediglich Nachrichten eines bestimmten Absenders zu bearbeiten, d.h. zu lesen, abzuspeichern und zu löschen. Diese Neigung des Benutzers zur selektiven Bearbeitung seiner elektronischen Post spiegelt sich in der Auswahl der entsprechenden Planspezifikationen in der ersten Phase des Systemlaufs wider. Alle diese Formeln beschreiben dieses typische Verhalten Spocks. Im Einzelnen gliedert sich der Ablauf des Gesamtsystems in folgende Phasen:

Selektionsphase: Nach der Identifizierung des aktuellen Benutzers werden aufgrund

der Information aus dem Benutzermodell die am höchsten bewerteten Planspezifikationen ausgewählt.

Generierungsphase: Diese Spezifikationen werden dem Plangenerierer übergeben, der sowohl durch Wiederverwendung und Modifikation alter Pläne als auch durch “konventionelle” deduktive Generierung mittels eines konstruktiven Beweises der jeweiligen Spezifikationsformel abstrakte Pläne erzeugt, die diese Spezifikationen erfüllen.

Klassifikationsphase: Gemäß dem in Abschnitt 7.3.2.1 beschriebenen Verfahren werden diese Pläne in Klassen eingeteilt und mit einer initialen numerischen Bewertung versehen.

Transformationsphase: Die Planformeln werden äquivalenzerhaltend in gerichtete Graphen übersetzt, um die Effizienz des Planerkennungsprozesses zu verbessern.

Interaktionsphase: Der Benutzer beginnt seine Interaktion mit dem Anwendungssystem und wird dabei vom Planerkenner beobachtet. Sobald eine Planhypothese eines der Auswahlkriterien erfüllt, wird diese dem Benutzer zur semantischen Vervollständigung und gegebenenfalls zur Optimierung angeboten.

```

conj((meta(Plan) &
      ((forall x : ((sender(msg(x,system_mbox))=s) ~~>
                    (delete_flag(msg(x,system_mbox))=0))) &
      (open_flag(system_mbox)=1)
-->
disj(sometimes(
      (screen_display =
      select_msgs_with_specific_sender(s,system_mbox))&
      sometimes((screen_display=all_folder_names(system_mbox)) &
                (forall x :
                  ((sender(msg(x,system_mbox))=s) ~~>
                    ((read_flag(msg(x,system_mbox))=1) &
                     (save_file(msg(x,system_mbox))=y) &
                     (delete_flag(msg(x,system_mbox))=1)))) &
                (open_flag(system_mbox)=0))))))

```

Abbildung 7.4: Die Planspezifikation p1 in interner Darstellung.

Die Selektionsphase

Aufgrund der numerischen Bewertung der vorhandenen Planspezifikationen, die im Benutzermodell abgespeichert ist und auf dem bisher beobachteten Verhalten des

```

(ex(from(sender,system_mbox)) & next next false) chop
(ex(folders(system_mbox)) & next next false) chop
((n := 1) & next next false) chop
while(n < mbox_length(system_mbox),
  if(sender(msg(n,system_mbox))=sender,
    ((ex(type(msg(n,system_mbox))) & next next false) chop
      (ex(save(msg(n,system_mbox),y)) & next next false) chop
      (ex(delete(msg(n,system_mbox))) & next next false)),
    ex(empty_action) & next next false ) chop
  ((n := n+1) & next next false) ) chop
ex(quit(system_mbox))

```

Abbildung 7.5: Der aus Spezifikation p1 generierte Plan.

Benutzers aufbaut, werden die vier am besten bewerteten Planspezifikationen zur Generierung von Plänen ausgewählt. Im konkreten Beispiel handelt es sich dabei um die Spezifikationen p1 – p4. Die erste davon ist bis auf die Deklaration der auftretenden Variablen in Abbildung 7.4 in interner Repräsentation dargestellt.

Die Interpretation dieser Formel ist folgende. Wird der noch unbekannte Plan `Plan` in einer Situation ausgeführt, in der alle Nachrichten eines bestimmten Absenders `sender` *nicht* gelöscht sind und die Mailbox `system_mbox` geöffnet ist, so werden irgendwann Zustände erreicht, in denen alle Nachrichten von `sender` auf dem Bildschirm angezeigt, gelesen, abgespeichert und gelöscht sind sowie die Mailbox `system_mbox` geschlossen ist.

Die Menge aller in dieser Phase ausgewählten Planspezifikationen ist in Anhang B aufgeführt.

Die Generierungsphase

Der Plangenerierer erzeugt aus diesen Spezifikationen Pläne, die den Namen ihrer zugehörigen Planspezifikation erhalten. Der aus p1 generierte Plan ist mit Ausnahme der zugehörigen Vorbedingungen in Abbildung 7.5 dargestellt. Er besteht aus einem sequentiellen Teil mit den Kommandos `from` und `folders`, einer `while`-Schleife und dem `quit`-Kommando. Der Rumpf der Schleife selbst beinhaltet wiederum eine Verzweigung, die für alle Nachrichten `n`, deren Absender `sender` ist, `type`, `save` und `delete`, für alle anderen die leere Aktion `empty_action` ausführt.

Alle vom Plangenerierer erzeugten Pläne sind in Anhang B aufgeführt.

Die Klassifikationsphase

Zur Klassifikation der soeben generierten Pläne stehen die in Anhang B aufgelisteten Teilpläne und Zielformeln als Klassifikationskriterien mit den zugehörigen numerischen Bewertungen aus dem Benutzermodell zur Verfügung. Plan p1 erfüllt beispiels-

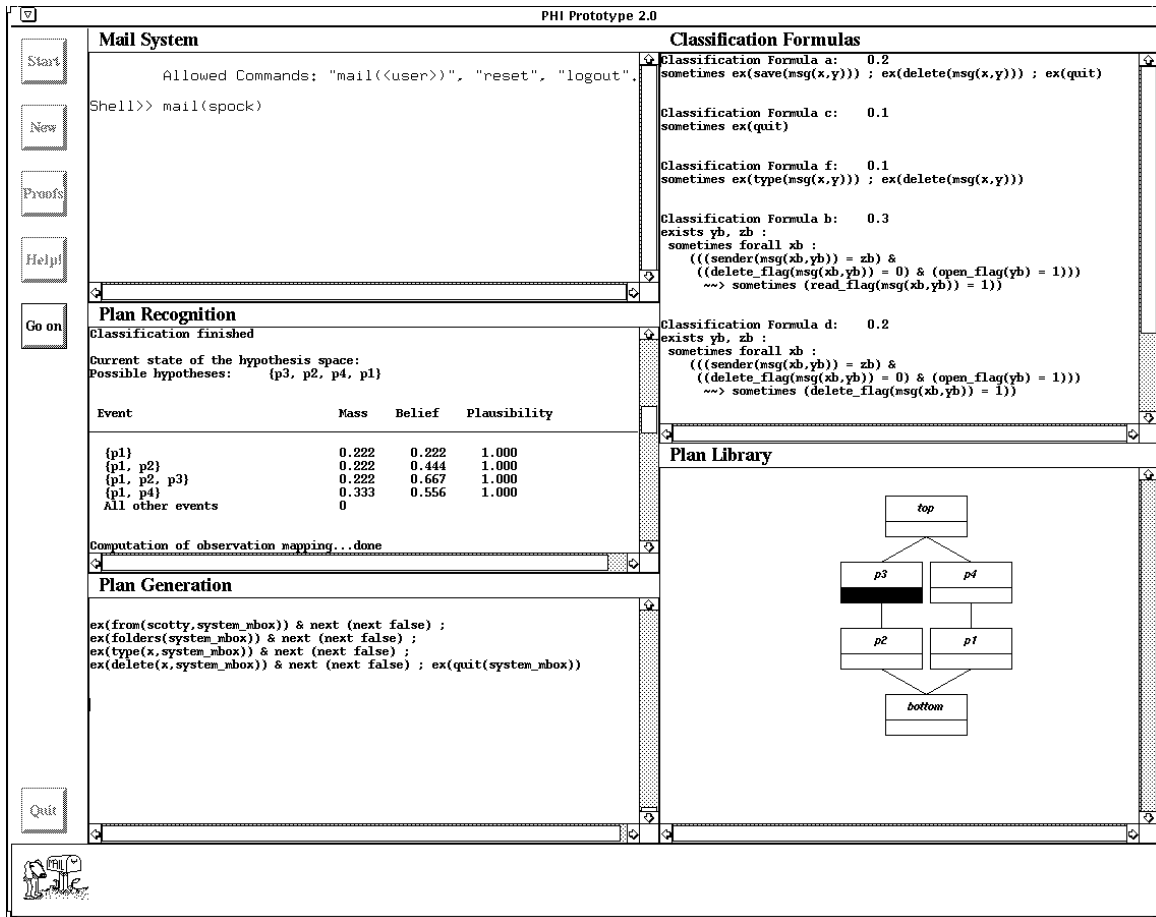


Abbildung 7.6: Das PHI-System nach der Klassifikationsphase.

weise alle Kriterien außer *f*. Die resultierende Planhierarchie mit ihrer initialen Bewertung der Planhypothesen ist ebenfalls im Anhang zu sehen. Am Ende der Klassifikationsphase werden die Beobachtungsregeln durch Parsen der Planformeln aufgestellt. Die numerischen Gewichte werden mangels spezifischerer Information gemäß dem in Abschnitt 6.1.3.2 beschriebenen Verfahren initialisiert.

Die in der Klassifikationsphase berechnete initiale Hypothesenbewertung hat folgendes Aussehen (siehe auch Abbildung 7.6):

$$m_0(X) = \begin{cases} 0.222, & X = \{ p1 \} \\ 0.222, & X = \{ p1, p2 \} \\ 0.222, & X = \{ p1, p2, p3 \} \\ 0.333, & X = \{ p1, p4 \} \\ 0, & \text{sonst} \end{cases}$$

Die Interaktionsphase

In Abhängigkeit von den Benutzerkommandos und der vom abduktiven Planerkenner

gelieferten Information bzgl. der Gültigkeit von Constraints und Vorbedingungen der einzelnen Pläne wird nun schrittweise die Hypothesenbewertung aktualisiert.

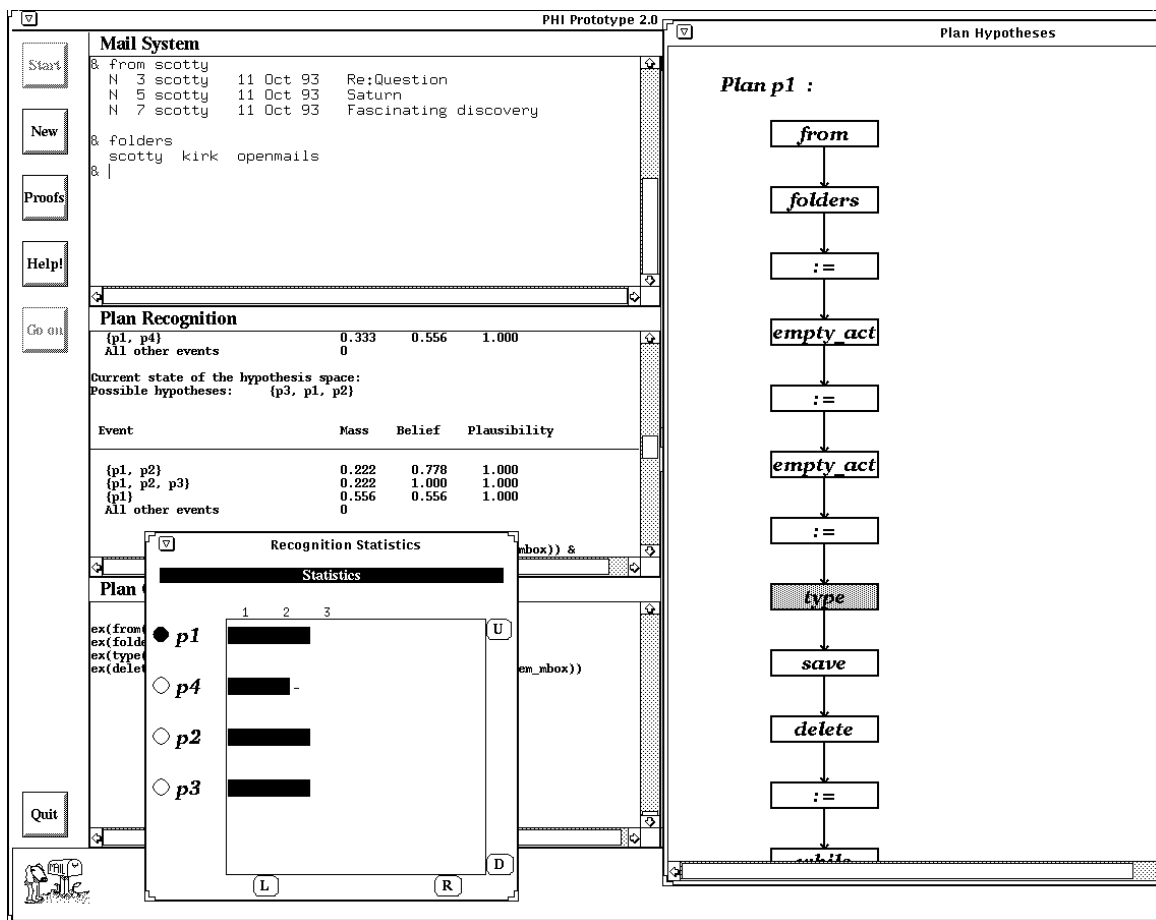


Abbildung 7.7: Das PHI-System nach Verwerfen der Hypothese p4.

Nach Eingabe des Kommandos `from scotty` ändert sich die initiale Bewertung nicht, da alle Pläne diese Aktion beinhalten und die entsprechenden Constraints erfüllt sind, d.h. $m_1 = m_0$. Das Kommando `folders` jedoch führt dazu, daß Hypothese p4 verworfen werden muß, da diese eine andere Aktion erwartete und ihre temporale Struktur keine Unterbrechung durch ein anderes Kommando erlaubt (siehe dazu Anhang B). Die zu `folders` gehörende Beobachtungsregel gehört daher zur Klasse *IB* (siehe Tabelle 6.1). Als aktualisierte Hypothesenbewertung erhält man somit

$$m_2(X) = \begin{cases} 0.556, & X = \{ p1 \} \\ 0.222, & X = \{ p1, p2 \} \\ 0.222, & X = \{ p1, p2, p3 \} \\ 0, & \text{sonst} \end{cases}$$

Abbildung 7.7 zeigt die Oberfläche des PHI-Systems nach der Verarbeitung dieser Beobachtung, wobei auch die Graphrepräsentation des Planes p1 und ein Balkendiagramm zur Überwachung des aktuellen Status der einzelnen Hypothesen sichtbar sind.

Nach der zweiten Benutzeraktion hat die Plausibilität $Pl_{m_2}(\{p1\})$ den Wert Null, d.h. dieser Plan ist als Hypothese für den aktuellen Interaktionszyklus endgültig verworfen. Die induzierte pignistische Wahrscheinlichkeit mit den Werten

$$P_0(X) = \begin{cases} 0.741, & X = \{ p1 \} \\ 0.185, & X = \{ p2 \} \\ 0.074, & X = \{ p3 \} \\ 0.000, & X = \{ p4 \} \end{cases}$$

weist sehr stark auf Hypothese p1 hin. Da der vorgegebene Schwellwert von 0.666 überschritten ist, wird der entsprechende Plan dem Benutzer zur semantischen Planvervollständigung angeboten. Enthält dieser suboptimale Aktionsfolgen, so kann der Plan zusätzlich durch den deduktiven Plangenerierer optimiert werden.

7.4 Eingliederung in das Projekt RAP

Während das Ziel des Projektes PHI die Entwicklung des Kernes für ein Hilfesystem war, der Planerkennung, Plangenerierung usw. in einer festen Konfiguration enthielt, so wurde in RAP der Schwerpunkt auf die flexible Konfigurierbarkeit dieser *Inferenzdienste* gelegt (siehe [Bauer *et al.*, 1996]). Diese können mit einer grafikbasierten *Shell* zu Systemen für spezielle Planungsaufgaben zusammengestellt werden. Die dabei entstehenden *Modulnetze* implementieren somit beispielsweise Planüberwachungssysteme, flexible Plangenerierer mit integrierter Reuse- und Planbibliothekskomponente, aber auch Hilfesysteme, wie sie Gegenstand der Untersuchungen von PHI waren.

Abbildung 7.8 zeigt die Gesamtarchitektur des RAP-Systems, die im generischen Teil auch das sogenannte “Domain Modeling Tool” enthält, das die systematische Modellierung einer Anwendungsdomäne unterstützt.

Zur Realisierung eines Modulnetzes wie in Abbildung 7.9 muß im wesentlichen lediglich der Datenfluß zwischen den Basismodulen aus der “Toolbox”, die die zur Verfügung stehenden Basisinferenzdienste realisieren, spezifiziert werden. Dies erfolgt durch einfaches Einfügen einer Kante zwischen zwei Modulen. Ein Vorteil dieser grafischen Eingabemöglichkeit liegt darin, daß die so entstehenden Modulnetze wesentliche Aspekte der jeweiligen *Architektur* des zu implementierenden Systems widerspiegeln.

Eine fest vorgegebene Abarbeitungsstrategie sorgt dafür, daß alle Module, deren *Eingabekanäle* mit Daten belegt sind, nach einer fairen Strategie zu einem bestimmten Zeitpunkt rechnen dürfen. Dieser starre Ablauf kann durch die Einführung sogenannter “Schalter” (Switches) beeinflußt werden. Diese im Modulnetz als Trapez gekennzeichneten Module führen jeweils einen bestimmten Test mit ihren aktuellen Eingabedaten aus und verzweigen den Kontrollfluß in Abhängigkeit vom Ergebnis

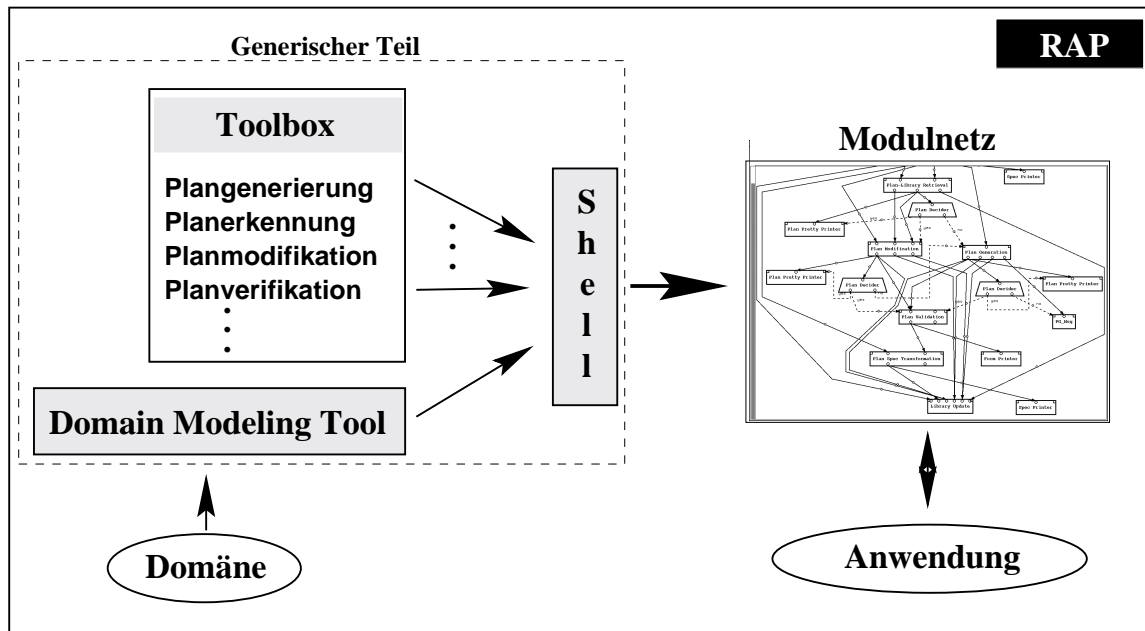


Abbildung 7.8: Die Architektur des RAP-Systems.

dieses Tests. Die einem solchen *Aktivierungssignal* entsprechenden Kanten sind im Modulnetz gestrichelt dargestellt. Ein Schalter entspricht einer bedingten Verzweigung, wie sie aus imperativen Programmiersprachen bekannt ist.

Das in Abbildung 7.9 dargestellte Modulnetz repräsentiert ein System, das Planerkennung und Benutzermodellierung mit einer Erklärungskomponente kombiniert. Nachdem ein Eingabemodul die benötigten Daten zum Laden des Benutzermodells und einer Planbibliothek eingelesen hat, werden die darin enthaltenen Pläne an die Graphtransformation des abduktiven Planerkennters (siehe Abschnitt 7.3.1) und an das Modul zur Initialisierung des Benutzermodells ("UM Init") übergeben. Der Planerkennters erhält von der Anwendungsschnittstelle die aktuellen Aktionen und Systeminformationen, wertet diese aus und gibt sie zur Abarbeitung an den Anwendungskern weiter.

Die Interaktion mit dem Hypothesenbewertungsmodul ("Hypo Assessment") erfolgt im wesentlichen wie in Abschnitt 7.3.2.2 beschrieben. Aus der Eingabe der letzten beobachteten Aktion und der Information bzgl. der Gültigkeit der Constraints wird unter Zuhilfenahme des Benutzermodells eine neue Hypothesenbewertung berechnet. Wird ein vom Benutzer zu wählendes Auswahlkriterium erfüllt, übersteigt also beispielsweise die Bewertung einer Hypothese einen bestimmten Schwellwert, so werden die Module zur Aktualisierung des Benutzermodells ("UM Update") und zur Ausgabe des Ergebnisses aktiviert. Zusätzlich wird die Erklärungskomponente aktiviert, die auf der Basis der jeweiligen numerischen Zwischenergebnisse nach den einzelnen Beobachtungen und der endgültigen Ausgabe des Systems die erforderlichen Berechnungen zur eventuellen Beantwortung von Benutzerfragen durchführt. Ist das Auswahlkriterium

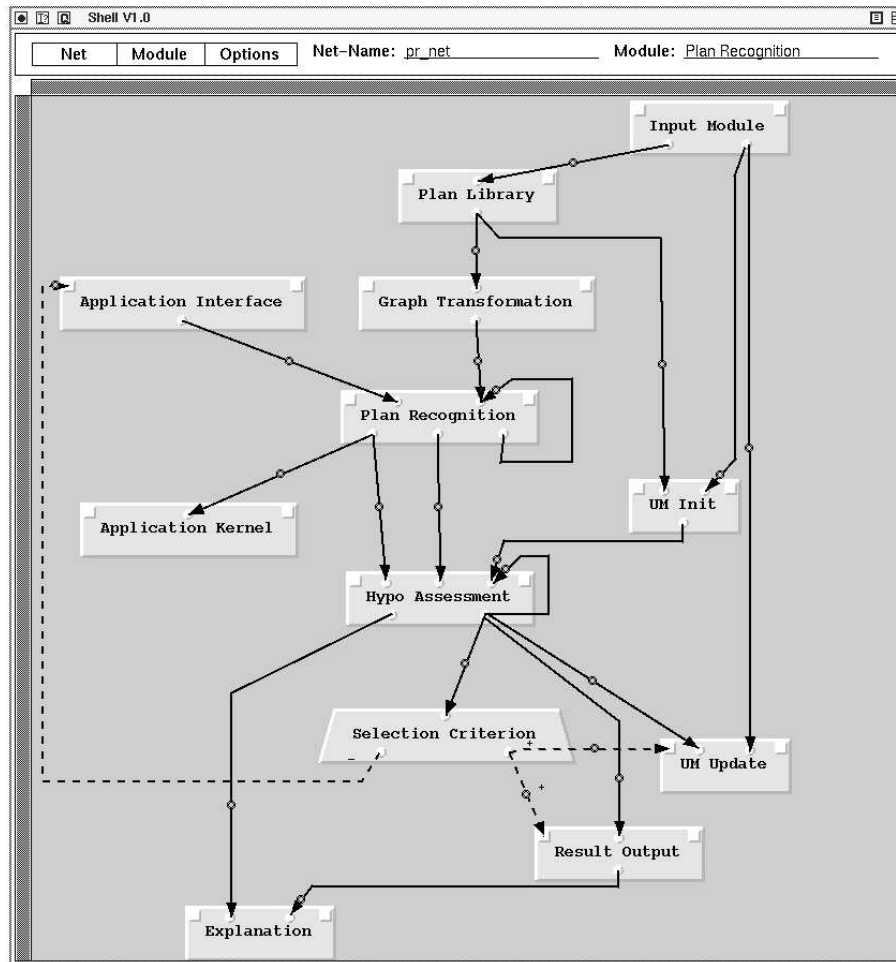


Abbildung 7.9: Ein Modulnetz mit Planerkennung und Erklärungskomponente.

nicht erfüllt, so wird der Kontrollfluß an das Anwendungssystem zurückgegeben und die nächste Benutzereingabe analysiert. Dies wird mit Hilfe des Schalters "Selection Criterion" realisiert.

Kapitel 8

Zusammenfassung und Ausblick

In der vorliegenden Arbeit wurde ein Ansatz zur Integration des Schließens unter Unsicherheit in die Planerkennung vorgestellt. Dieser erlaubt die Berücksichtigung agentenspezifischer Information, sog. *Präferenzen*, und somit eine schnellere und genauere Fokussierung auf “wahrscheinlichere” Planhypothesen. Zusätzlich bildet eine quantitative Bewertung die Grundlage für die Berechnung einer Rangfolge innerhalb der Hypothesenmenge, die dazu benutzt werden kann, entweder extrem niedrig bewertete Pläne frühzeitig zu verwerfen oder aber jederzeit die “beste” Hypothese auswählen zu können. Dies ist beispielsweise in Anwendungen wie intelligenten Hilfesystemen immer dann notwendig, wenn ein Anwender optimal unterstützt werden soll.

Damit wurde erstmals in der Planerkennung überhaupt der Tatsache Rechnung getragen, daß

- verschiedene Individuen sich selbst bei gleicher Zielsetzung innerhalb einer bestimmten Anwendung vollständig unterschiedlich verhalten und daher auch der Planerkennungsprozeß selbst an diese individuellen Verhaltensmuster adaptiert werden muß,
- die diesbezügliche Information über einen Agenten permanent an dessen tatsächliches Verhalten angepaßt und
- auch ohne dessen Unterstützung aus den Planerkennungsergebnissen abgeleitet werden muß.¹

Dies bildet die Grundlage für *adaptive Systeme*, die sowohl den persönlichen “Interaktionsstil” eines bestimmten Benutzers aktiv unterstützen als auch auf dessen mögliches Fehlverhalten mit einem maßgeschneiderten Hilfsangebot in Form einer Fehlermeldung oder sogar eines optimierten Planes reagieren können.

Zu diesem Zweck wurde ein Verfahren aus dem Bereich der Expertensysteme adaptiert, das formal auf der Dempster-Shafer Theorie aufbaut. Dabei handelt es sich um

¹Einzig [Calistri-Yeh, 1991] bildet hier mit dem Hinweis auf die Notwendigkeit der Berücksichtigung individuellen Verhaltens eine Ausnahme (siehe dazu die Abschnitte 3.2.1 und 3.4).

den in [Guan und Bell, 1991] vorgestellten Ansatz, der eine Erweiterung des in [Yen, 1989] beschriebenen Systems GERTIS darstellt. Diesem Ansatz wurde im Rahmen des *evidenzbasierten Schließens* [Ruspini, 1986] eine formale, wahrscheinlichkeitstheoretische Semantik gegeben.

Die Dempster-Shafer Theorie erlaubt die Modellierung einer Situation in einer dem aktuellen Wissensstand entsprechenden Granularität. Dies bedeutet, daß bestimmte Aspekte, über die keine oder nur unvollständige Information vorliegt, entsprechend markiert werden, und daß diese explizite Repräsentation partieller (oder sogar totaler) Unwissenheit in die Schlußfolgerungen mit einbezogen werden kann. Gerade dieser Aspekt spielt für die Anwendung dieses Formalismus auf die Planerkennung eine entscheidende Rolle. Das über einen bestimmten Agenten verfügbare Wissen, das in Form eines *quantitativen Benutzermodells* vorliegt, ist in den meisten Fällen sehr unspezifisch und äußerst unvollständig. Die Verwendung der Dempster-Shafer Theorie erlaubt es, nur diejenigen Aspekte im Verhalten eines Agenten genauer zu modellieren, über die tatsächlich Information vorliegt und andere als außerhalb des aktuellen Wissensstandes liegend zu kennzeichnen.

Die zweite wichtige Wissensquelle eines Planerkenners ist typischerweise eine *Planbibliothek*. Ihre Repräsentation als Hypothesenraum in der Dempster-Shafer Theorie erhält ihre charakteristische hierarchische Struktur mit Abstraktionsbeziehungen zwischen den verschiedenen Plänen. Die Dekomposition von Plänen spiegelt sich in einer Beobachtungsfunktion wider, die die beobachtbaren Aktionen als Evidenzen auf die Mengen der kompatiblen Planhypothesen abbildet und dabei zusätzlich die agentenspezifische Information berücksichtigt. Die dabei verwendeten Inferenzmechanismen erweitern die Dempster-Shafer Theorie um eine Methode zur Evaluierung *unsicherer* Verbindungen zwischen Evidenzen und Hypothesen.

Der resultierende Ansatz zur Bewertung der Hypothesen eines Planerkenners (einschließlich des Aufbaus und der Wartung des quantitativen Benutzermodells) kann leicht mit verschiedenen Planerkennungssystemen gekoppelt werden. Beispielhaft wurde dies in Abschnitt 6.2 für das in [Allen, 1991, Kapitel 2] von Kautz vorgestellte beschrieben. Die tatsächliche Kombination mit dem abduktiven Planerkenner des PHI-Systems ist Inhalt von Kapitel 7 (siehe dazu auch [Bauer und Paul, 1993]).

Um die Effizienz der vorgestellten Methoden zu erhöhen, wurden verschiedene Approximationsalgorithmen für Berechnungen in der Dempster-Shafer Theorie – darunter ein neu entwickelter – auf ihre Eignung bzgl. der Entscheidungsunterstützung untersucht. Die empirischen Ergebnisse sind in Abschnitt 6.5.2 dokumentiert.

Gegenwärtig wird eine Reimplementierung des im PHI-System integrierten Moduls zur Bewertung von Planhypothesen im Rahmen einer Diplomarbeit durchgeführt, die einerseits die vollständige Funktionalität einschließlich der Wartung des quantitativen Benutzermodells für die Komponenten der RAP-Shell zur Verfügung stellt, andererseits aber auch klar definierte Schnittstellen nach außen besitzt, die eine softwaremäßige Kopplung mit existierenden Planerkennungssystemen erlaubt.

Der vorgestellte Ansatz bezieht seine numerischen Informationen im Wesentlichen aus der Analyse des Langzeitverhaltens der zu beobachtenden Agenten. Dabei werden

neben der relativen Häufigkeit des Auftretens der verschiedenen Pläne auch Daten über das gleichzeitige Auftreten gewisser Aktionen und Pläne erfaßt. Diese erlauben eine Quantifizierung dessen, wie stark eine Beobachtung die verschiedenen Hypothesen unterstützt. Auch diese Information bezieht sich auf das *Langzeitverhalten* der Agenten, spiegelt also deren typisches Verhalten “im Durchschnitt” wider.

Bisher wurden dabei in erster Linie Systeme zur “Schlüsselloch-Planerkennung” (“keyhole recognition”) unterstützt. Das heißt, es wird davon ausgegangen, daß der beobachtete Agent den Erkennungsprozeß nicht aktiv unterstützt, indem er beispielsweise zur Disambiguierung mehrdeutiger Situationen beiträgt. Intelligente Hilfe- und Tutorssysteme sind typische Beispiele für diese Klasse von Anwendungen.

Zwar sind die in Kapitel 6 eingeführten Techniken ebenso auf Bereiche mit intendierter Erkennung anwendbar (Beispiele für diese Klasse finden sich in den Abschnitten 3.3.1 und 3.3.2), jedoch wird dabei nicht die gesamte zur Verfügung stehende Information ausgenützt. In diesen Fällen muß auch das Wissen um den Grad der Instantiierung einer Hypothese bzw. den Dialogkontext einer Äußerung als zusätzliche Evidenz berücksichtigt werden. Die Integration solcher Information in den Prozeß der Hypothesenbewertung stellt eine mögliche Erweiterung des vorgestellten Ansatzes dar.

Weiterhin wäre es sinnvoll, den Einsatz von Techniken des maschinellen Lernens auszudehnen. Die (manuelle) Erstellung einer möglichst vollständigen Planbibliothek für eine konkrete Domäne stellt eines der zentralen Probleme bei der Anwendung eines Planerkenners dar. Hier könnte es sinnvoll sein, regelmäßig wiederkehrende Aktionsfolgen eines Agenten aus dessen Langzeitverhalten zu lernen, um nach einer gewissen Abstraktion bzgl. temporaler und struktureller Constraints automatisch eine Planbibliothek aufbauen zu können. Neben dem Gebiet des “Data Mining” könnten hier auch Arbeiten aus dem Bereich des Konzeptlernens wie etwa [Yoshida *et al.*, 1994; Yoshida und Motoda, 1995] einen Beitrag leisten.

Im Zusammenhang mit der Planbibliothek stellt sich eine weitere Aufgabe. Um in dynamischen Domänen wie beispielsweise Internet-Anwendungen erfolgreich arbeiten zu können, ist es notwendig, die Annahme der Vollständigkeit des vorgegebenen Hypothesenraumes aufzugeben. Vielmehr ist es hier durch die Vielzahl neu entstehender bzw. nach einer gewissen Zeit nicht mehr verfügbarer Dienstleistungen und die sich daraus ergebenden Veränderungen der einem Agenten möglichen Handlungen notwendig, die Planbibliothek ebenfalls dynamisch modifizieren und das Fehlen eines Planes in Betracht ziehen zu können.

Als zentrales Ergebnis der vorliegenden Arbeit ist festzuhalten, daß der in Kapitel 6 vorgestellte Ansatz die quantitative Modellierung wesentlicher Aspekte im Verhalten eines Agenten erlaubt und somit den Planerkennungsprozeß unterstützt, indem er unter anderem

- die frühzeitige Eliminierung extrem schlecht bewerteter Hypothesen,
- die Berechnung einer “Rangfolge” der einzelnen Pläne und somit

- die Auswahl der *in bezug auf den aktuell beobachteten Agenten* “besten” Hypothese zu jedem Zeitpunkt ermöglicht und somit die Grundlage für adaptives Systemverhalten bildet.

Die Verwendung der Dempster-Shafer Theorie zur formalen Untermauerung dieses Ansatzes erlaubt dabei selbst bei unvollständigem Wissen über den zu beobachtenden Agenten – der typischen Situation – eine zumindest approximative Modellierung seines Verhaltens und damit eine konsistente Bewertung der sich ergebenden Planhypothesen.

Anhang A

Exkurs: Algebraische Charakterisierung maßfreier Konditionale

Sei wie in Abschnitt 4.2.1 wiederum eine *endliche* Boolesche Algebra \mathcal{B} gegeben, deren Elemente a, b, \dots als *Aussagen* bezeichnet werden. Dem in [Dubois und Prade, 1991] beschriebenen Ansatz folgend, werden zunächst anhand von Wahrheitstafeln notwendige Bedingungen für die exakte Definition des Konditionals hergeleitet. Dazu bezeichne $tr(x)$ den Wahrheitswert von x . Die Tabellen 4.1 und 4.2 enthalten die entsprechenden Werte für Implikation und Konditionierung.

Der Wert $tr(a|b)$ kann auch implizit definiert werden durch

$$tr(a \wedge b) = tr(a|b) * tr(b), \quad (4.20)$$

wobei $T * T = T$ und $T * F = F * T = F * F = F$ die Verknüpfung der Wahrheitswerte ist:

1. Ist $tr(a) = tr(b) = T$, so folgt aus (4.20), daß $tr(a|b) = T$.
2. Ist $tr(a) = F$, $tr(b) = T$, so ist $tr(a|b) = F$.
3. Ist $tr(b) = F$, so sind sowohl $tr(a|b) = T$, als auch $tr(a|b) = F$ mit (4.20) kompatibel.

Somit gilt, daß jede Aussage x mit $tr(a \wedge b) = tr(x) * tr(b)$ für $a|b$ stehen kann. Beschränkt man sich auf Boolesche Ausdrücke über a und b , so gibt es 4 Kandidaten für dieses x , nämlich $a \wedge b$, a , $a \leftrightarrow b$ und $b \rightarrow a$, wobei $a \leftrightarrow b$ für die Äquivalenz $(a \rightarrow b) \wedge (b \rightarrow a)$ steht.

Notation: Die Aussagenmenge

$$\{a \wedge b, a, a \leftrightarrow b, b \rightarrow a\} \quad (A.1)$$

wird mit $a|_1 b$ bezeichnet.

In [Spies, 1991] wird $a|_1b$ als *termgeneriertes konditionales Objekt* (*term-generated conditional object*) bezeichnet. Diese Menge ist partiell geordnet bzgl. der durch die Algebraoperationen induzierten Relation $x \leq y : \iff x \wedge y = x$. Es gilt nämlich:

$$a \wedge b \leq a \leq b \rightarrow a \quad \text{und} \quad a \wedge b \leq a \leftrightarrow b \leq b \rightarrow a.$$

Anmerkungen:

1. Diese partielle Ordnung kann auch mengentheoretisch interpretiert werden als $x \subseteq y : \iff x \cap y = x$.
2. Es besteht eine enge Verbindung zwischen der partiellen Ordnung \leq auf den Elementen der Booleschen Algebra \mathcal{B} und dem Konzept der logischen Implikation \Rightarrow , das in Abschnitt 4.1.1 diskutiert wurde. Es gilt nämlich für $\alpha, \beta \in \text{Obj}(\mathcal{S})$: $\alpha \Rightarrow \beta$ genau dann, wenn $\alpha \leq \beta$ in der Algebra $\langle \text{Obj}(\mathcal{S}), \vee, \wedge, \neg, \top, \perp \rangle$. Aus diesem Grund wird \leq auch als *Folgerbarkeitsrelation* (*entailment relation*) bezeichnet.
3. In [Spies, 1991] werden die vier Elemente eines termgenerierten konditionalen Objekts aus (A.1) folgendermaßen charakterisiert: Das bzgl. \leq kleinste Element $a \wedge b$ entspricht dem Grad der Verifikation der "Regel" $a|b$, während das größte Element $b \rightarrow a$ das Komplement der dem Grad der Falsifizierung der Regel entsprechenden Menge $b \wedge \neg a$ ist. a entspricht dann der "Basisrate", und $a \leftrightarrow b$ enthält sowohl alle positiven Beispiele für die Anwendung der Regel $a|b$ – nämlich $a \wedge b$ –, als auch alle irrelevanten Situationen, in denen weder a noch b gilt. Dementsprechend gelten für jede Wahrscheinlichkeitsfunktion P die folgenden Grenzen:

$$P(a \wedge b) \leq P(a|b) \leq P(b \rightarrow a). \quad (\text{A.2})$$

Definition A.0.1 (Grad der Verifikation und Falsifizierung)

In obiger Situation bezeichnet $P(a \wedge b)$ den *Grad der Verifikation*, während $P(\neg a \wedge b)$ der *Grad der Falsifizierung* des konditionalen Objekts $a|b$ ist.

In der Literatur finden sich mehrere äquivalente Definitionen des Konditionals $a|b$, die zum Teil auf den Ringeigenschaften einer Booleschen Algebra aufbauen:

Definition A.0.2 [Goodman und Nguyen, 1988]

Für alle $a, b \in \mathcal{B}$:

$$a|_2b = \{x \in \mathcal{B} \mid x \wedge b = a \wedge b\}. \quad (\text{A.3})$$

Definition A.0.3 [Calabrese, 1987]

Für alle $a, b \in \mathcal{B}$:

$$a|_3b = \{x \in \mathcal{B} \mid \exists r \in \partial(b), x \wedge r = a \wedge r\}, \quad (\text{A.4})$$

wobei $\partial(b) = \{b \vee s \mid s \in \mathcal{B}\}$.

In dieser Definition ist also $\partial(b) = \{x \mid b \leq x\}$. Es kann gezeigt werden, daß (A.3) und (A.4) äquivalent sind. Weiterhin gilt, daß $a|_2b = a|_1b$, sobald man sich in Definition A.0.2 auf Boolesche Funktionen über a und b als mögliche Werte für x beschränkt. Dabei müssen a und b *voneinander unabhängig* sein, d.h.

$$\forall x \in \{a \wedge b, \neg a \wedge b, a \wedge \neg b, \neg a \wedge \neg b\} : x \neq \perp.$$

Im allgemeinen Fall kann die partielle Ordnungsrelation auf \mathcal{B} mit $a \leq b : \iff a \wedge b = a$ zu einer kompakten Repräsentation für $a|_2b$ in *Intervallnotation* benutzt werden:

$$a|_2b = \{x \in \mathcal{B} \mid a \wedge b \leq x \leq \neg b \vee a\} = [a \wedge b, \neg b \vee a]. \quad (\text{A.5})$$

In neueren Arbeiten wie [Nguyen und Rogers, 1991] und [Spies, 1991] werden konditionale Objekte als Partition eines Booleschen Ringes modulo eines Hauptideals betrachtet. Dort wird $a|_2b$ entsprechend im mit der Algebra \mathcal{B} assoziierten Booleschen Ring $\mathcal{R}^{\mathcal{B}}$ als

$$a|_{2,\mathcal{R}}b = \{x \in \mathcal{R}^{\mathcal{B}} \mid x \cdot b = a \cdot b\} \quad (\text{A.6})$$

bzw. äquivalent dazu als

$$a|_{2,\mathcal{R}}b = \{x \in \mathcal{R}^{\mathcal{B}} \mid x = a \cdot b + y \cdot b' \ \forall y \in \mathcal{R}^{\mathcal{B}}\} \quad (\text{A.7})$$

definiert. Die Äquivalenz von (A.6) und (A.7) ist leicht einzusehen, wenn man die Ringoperationen $+$ und \cdot mengentheoretisch interpretiert. Denn es ist offensichtlich, daß jedes $x \in \mathcal{R}^{\mathcal{B}}$, das mit b den gleichen Durchschnitt hat wie a , aus eben diesem Durchschnitt $a \cdot b$ sowie einem “außerhalb” b 's, d.h. in dessen Komplement b' liegenden Teil $y \cdot b'$ besteht. Da beide Komponenten von x disjunkt sind, gilt

$$a \cdot b + y \cdot b' = a \cdot b + y \cdot b' + (a \cdot b) \cdot (y \cdot b'),$$

was mengentheoretisch der Vereinigung $(a \cap b) \cup (y \cap \bar{b})$ entspricht (vergleiche dazu die Anmerkungen zu Satz 4.2.1).

Betrachtet man das Hauptideal $\mathcal{R}^{\mathcal{B}} b'$, so kann $a|_{2,\mathcal{R}}b$ äquivalent dargestellt werden als

$$[a|b] = a + \mathcal{R}^{\mathcal{B}} b', \quad (\text{A.8})$$

so daß die konditionalen Objekte eines gegebenen Antezedenten b Äquivalenzklassen in der Partition $\mathcal{R}^{\mathcal{B}}/\mathcal{R}^{\mathcal{B}} b'$ bilden. Das bedeutet, das konditionale Objekt zu einer bestimmten Konsequenz a ist die Äquivalenzklasse, die a enthält.

Anmerkung: $\mathcal{R}^{\mathcal{B}} b' = \{x \cdot b' \mid x \in \mathcal{R}^{\mathcal{B}}\}$ ist offensichtlich ein Ideal, da

1. $\mathcal{R}^{\mathcal{B}} b'$ nicht leer ist,
2. für $r_1 = x_1 \cdot b', r_2 = x_2 \cdot b' \in \mathcal{R}^{\mathcal{B}} b'$ auch $r_1 + r_2 = (x_1 + x_2) \cdot b' \in \mathcal{R}^{\mathcal{B}} b'$ gilt und
3. für $r_1 \in \mathcal{R}, r_2 = x_2 \cdot b' \in \mathcal{R}^{\mathcal{B}} b'$ auch $r_1 \cdot r_2 = (r_1 \cdot x_2) \cdot b' \in \mathcal{R}^{\mathcal{B}} b'$ ist.

Die systematische Ableitung dieser Ergebnisse wird in [Nguyen und Rogers, 1991] beschrieben. Ausgehend von einem Booleschen Ring $\mathcal{R} = \langle R, +, \cdot, 0, 1 \rangle$ bzw. der entsprechenden Booleschen Algebra $\langle R, \vee, \cdot, ', 0, 1 \rangle$, die hier ebenfalls mit \mathcal{R} bezeichnet wird,¹ wird eine Abbildung

$$f : \mathcal{R} \times \mathcal{R} \rightarrow \mathcal{S}_K$$

gesucht, die alle grundlegenden Aspekte der Konditionierung umfaßt und mit bedingten Wahrscheinlichkeiten kompatibel ist. \mathcal{S}_K ist dabei der noch unbekannte Raum der bedingten Ereignisse, der gemäß Lewis' Trivialitätsresultat (siehe Satz 4.2.2) echt größer als \mathcal{R} sein muß:

Beispiel A.0.1 Betrachtet man etwa den Operator $g : \mathcal{R} \times \mathcal{R} \rightarrow \mathcal{R}$ mit $g(a, b) = ab$, was im logischen Sinne der Konjunktion von a und b entspricht, so gilt zwar

$$g(a, 1) = a \text{ für alle } a \text{ und}$$

$$g(ab, b) = g(a, b) \text{ für alle } a \text{ und } b,$$

was mit den gewünschten Eigenschaften eines Konditionaloperators übereinstimmt. Gleichzeitig gilt aber für alle Wahrscheinlichkeiten P , daß $P(g(a, b)) = P(ab) \neq P(a|b)$. Außerdem ist es für bestimmte $a, b, c, d \in \mathcal{R}$ mit $P(b) > 0$ und $P(d) > 0$ möglich, daß $ab = cd$, obwohl $b \neq d$. Somit gilt, daß $g(a, b) = g(c, d)$, aber nicht unbedingt auch $P(a|b) = P(c|d)$.

Bezeichnet man nun für ein festes $b \in \mathcal{R}$ den Wertebereich von $f(\cdot, b)$ mit $\mathcal{R}b \subseteq \mathcal{R}$, so ist der Wertebereich für f gegeben durch

$$\mathcal{S}_K = \bigcup_{b \in \mathcal{R}} \mathcal{R}b. \quad (\text{A.9})$$

Betrachtet man (A.9) als *disjunkte* Vereinigung, so ist \mathcal{S}_K echt größer als \mathcal{R} . Sind etwa $b \neq d \in \mathcal{R}$ und $db \in \mathcal{R}b$, $bd \in \mathcal{R}d$, so gilt zwar $db = bd$ in \mathcal{R} , aber $db \neq bd$ in \mathcal{S}_K .

Notation: Zur Unterscheidung wird ein Element $a \in \mathcal{R}b$ als

$$(a, b) \in \mathcal{R}b$$

geschrieben. Für die Gleichheit gilt dann $(a, b) \neq (a, d)$, falls $b \neq d$, womit zum Ausdruck kommt, daß die Konditionierung bzgl. unterschiedlicher Ereignisse zu unterschiedlichen konditionalen Ereignissen führt.

Bezieht man die Disjunktheit der Vereinigung in (A.9) in die Definition von g aus obigem Beispiel ein, so wird g kompatibel mit bedingten Wahrscheinlichkeiten:

$$g(a, b) = (a, b) \in \mathcal{R}b.$$

¹In den folgenden Ausführungen wird nicht mehr der Unterschied zwischen der Algebra $\mathcal{B}^{\mathcal{R}}$ und dem Ring $\mathcal{R}^{\mathcal{B}}$ gemacht, da beide gemäß Satz 4.2.1 äquivalent sind. Aus dem Kontext wird anhand der verwendeten Operationen klar werden, ob es sich dabei um Ring- oder Algebraoperationen handelt.

Es ist nun möglich, einem solchen Ereignis eine bedingte Wahrscheinlichkeit zuzuordnen:

$$P((a, b)) = P(a|b).$$

Definition A.0.4 (Konditionaloperator)

Ein Konditionaloperator ist eine Abbildung $f : \mathcal{R} \times \mathcal{R} \rightarrow \mathcal{S}_K$ mit

1. $f(a, b) = f(ab, b)$ für alle $a, b \in \mathcal{R}$,
2. ist $f(a, b) = f(c, d)$, so folgt $b = d$,
3. f ist kompatibel mit Wahrscheinlichkeiten, d.h. wenn $f(a, b) = f(c, d)$ ist, so folgt für alle Wahrscheinlichkeiten auf \mathcal{R} mit $P(b) > 0$ und $P(d) > 0$: $P(a|b) = P(c|d)$.

Punkt 3. kann für den Fall, daß \mathcal{R} atomar ist, d.h. wenn jedes Element aus \mathcal{R} als Vereinigung von Atomen darstellbar ist, folgendermaßen modifiziert werden:

4. $f(a, b) = f(c, d)$ impliziert $ab = cd$.

Dies hat zur Folge, daß \mathcal{R} isomorph zu $f(\mathcal{R}, 1)$ ist.

Sei nun folgende Äquivalenzrelation auf \mathcal{R} definiert:

$$x \approx_{f,b} y \iff f(x, b) = f(y, b) \tag{A.10}$$

Ziel ist es nun, eine Abbildung f mit den Eigenschaften 1., 2. und 4. zu finden. Sei dazu für jedes $b \in \mathcal{R}$

$$f(\cdot, b) : \mathcal{R} \rightarrow f(\mathcal{R}, b) = \mathcal{S}_b.$$

Um 1. zu erfüllen, muß die Einschränkung von $f(\cdot, b)$ auf $\mathcal{R}b$ surjektiv sein. Denn jedes $a \in \mathcal{R}$ ist äquivalent bzgl. $\approx_{f,b}$ zu einem Element $ab \in \mathcal{R}b$. Daher müssen alle bedingten Ereignisse mit Antezedenten b bereits durch die Elemente in $\mathcal{R}b$ mittels f generierbar sein, d.h. $f(\mathcal{R}, b) = f(\mathcal{R}b, b)$. Dagegen setzt Bedingung 4. die Injektivität dieser Einschränkung von f voraus.

Somit induziert $f(\cdot, b)$ einen natürlichen Booleschen Ring auf \mathcal{S}_b mit den Operationen $+_b, \cdot_b, 0_b$ und 1_b , wodurch $f(\cdot, b) : \mathcal{R} \rightarrow \mathcal{S}_b$ zum Homomorphismus wird. Dessen Kern sei mit $I(b)$ bezeichnet und soll im folgenden bestimmt werden:²

$$I(b) = \{x \in \mathcal{R} | f(x, b) = f(0, b) = 0_b\}.$$

Dann läßt sich (A.10) wie folgt schreiben:

$$x \approx_{f,b} y \iff f(x, b) = f(y, b) \iff x + y \in I(b).$$

²Ist der Kern von f bekannt, so ist $\mathcal{R}/I(b)$ bis auf Isomorphie eindeutig bestimmt.

Sei nun $\hat{f}(\cdot, b) : \mathcal{R} \rightarrow \mathcal{R}/I(b)$ mit

$$\hat{f}(a, b) = a + I(b),$$

d.h. $\hat{f}(\cdot, b)$ ist der kanonische Homomorphismus, der jedem a die es enthaltende Äquivalenzklasse zuordnet. Wegen 1. gilt dann $a \approx_{f,b} ab$ für alle $a \in \mathcal{R}$ und somit

$$a + ab = ab' \in I(b).$$

Betrachtet man alle $a \in \mathcal{R}$, so erhält man

$$\mathcal{R}b' \subseteq I(b). \quad (\text{A.11})$$

Sei nun umgekehrt $a \in I(b)$. Dann gilt

$$f(a, b) = f(ab, b) = f(0, b) = 0_b.$$

Da die Einschränkung von $f(\cdot, b)$ auf $\mathcal{R}b$ aber ein Isomorphismus ist, folgt $ab = 0$. Somit kann a dargestellt werden als xb' mit $x \in \mathcal{R}$, also $a \in \mathcal{R}b'$. Folglich gilt

$$I(b) \subseteq \mathcal{R}b'. \quad (\text{A.12})$$

Somit ist gemäß (A.11) und (A.12) der Kern von f bestimmt:

$$I(b) = \mathcal{R}b'.$$

Die obige Definition von \hat{f} wird also zu

$$\hat{f}(a, b) = a + \mathcal{R}b' \in \mathcal{R}/\mathcal{R}b'.$$

\hat{f} erfüllt die Anforderungen 1., 2. und 4. Da \mathcal{S}_b isomorph zu $\mathcal{R}/\mathcal{R}b'$ ist, kann man alle f , die diese Bedingungen ebenfalls erfüllen, durch Bijektionen aus \hat{f} erhalten. Die *kanonische Form* eines Konditionals $a|b$ ist $a + \mathcal{R}b'$, der *Raum der bedingten Ereignisse* ist

$$\mathcal{R}|\mathcal{R} = \bigcup_{b \in \mathcal{R}} \mathcal{R}/\mathcal{R}b'.$$

Dies beendet die formale Fundierung des Ergebnisses von Gleichung (A.8), in der konditionale Ereignisse als Äquivalenzklassen dargestellt werden, wobei der Konditionaloperator dem kanonischen Homomorphismus entspricht.

Anhang B

Daten zum Beispiellauf des PHI-Systems

Alle Formeln sind hier in der internen Repräsentation des PHI-Systems dargestellt.
Die Menge der in der Selektionsphase ausgewählten Planspezifikationen.

```
plan_specification(p1,
[global_var(x,integer),
 global_var(y,filename),
 global_var(system_mbox,mbox),
 local_var(screen_display,list),
 local_var(n,integer),
 global_var(s,sender)], [],
((meta(_) &
 (forall x : ((sender(msg(x,system_mbox))=s) ~~>
(delete_flag(msg(x,system_mbox))=0))) &
 (open_flag(system_mbox)=1))

~~>
sometimes((screen_display = select_msgs_with_specific_sender(s,system_mbox))&
 sometimes( (screen_display=all_folder_names(system_mbox)) &
 (forall x : ((sender(msg(x,system_mbox))=s) ~~>
((read_flag(msg(x,system_mbox))=1) &
 (save_file(msg(x,system_mbox))=y) &
 (delete_flag(msg(x,system_mbox))=1)))) &
 (open_flag(system_mbox)=0))))).
```

```
plan_specification(p2,
[global_var(x,integer),
 global_var(y,filename),
 global_var(system_mbox,mbox),
 local_var(screen_display,list),
 global_var(s,sender)], [],
((meta(_) &
 (delete_flag(msg(x,system_mbox))=0) &
```

```

(sender(msg(x,system_mbox))=s) &
(open_flag(system_mbox)=1))
~~>
sometimes((screen_display = select_msgs_with_specific_sender(s,system_mbox))&
  sometimes( (screen_display=all_folder_names(system_mbox)) &
(read_flag(msg(x,system_mbox))=1) &
(save_file(msg(x,system_mbox))=y) &
(delete_flag(msg(x,system_mbox))=1) &
  (open_flag(system_mbox)=0))))).

plan_specification(p3,
[global_var(x,integer),
 global_var(y,filename),
 global_var(system_mbox,mbox),
 local_var(screen_display,list),
 global_var(s,sender)], [],
((meta(_) &
 (delete_flag(msg(x,system_mbox))=0) &
 (sender(msg(x,system_mbox))=s) &
 (open_flag(system_mbox)=1))
~~>
sometimes((screen_display = select_msgs_with_specific_sender(s,system_mbox))&
  sometimes( (screen_display=all_folder_names(system_mbox)) &
(read_flag(msg(x,system_mbox))=1) &
(delete_flag(msg(x,system_mbox))=1) &
  (open_flag(system_mbox)=0))))).

plan_specification(p4,
[global_var(x,integer),
 global_var(y,filename),
 global_var(system_mbox,mbox),
 local_var(screen_display,list),
 local_var(n,integer),
 global_var(s,sender)], [],
((meta(_) &
 (forall x : ((sender(msg(x,system_mbox))=s) ~~>
(delete_flag(msg(x,system_mbox))=0))) &
 (open_flag(system_mbox)=1))

~~>
sometimes((screen_display = select_msgs_with_specific_sender(s,system_mbox))&
  (forall x : ((sender(msg(x,system_mbox))=s) ~~>
(read_flag(msg(x,system_mbox))=1))))).

```

Die Menge der in der Generierungsphase erzeugten Pläne einschließlich der zugehörigen Vorbedingungen.

Alle Pläne erhalten den Namen ihrer jeweiligen Planspezifikationsformel (s.o.).

p1:

```
((forall x : ((sender(msg(x,system_mbox))=s) ~~>
(delete_flag(msg(x,system_mbox))=0))) &
(open_flag(system_mbox)=1))
&
(ex(from(s,system_mbox))&next next false) chop
(ex(folders(system_mbox))&next next false) chop
((n := 1)&next next false) chop
while(n < length(system_mbox),
  if(sender(msg(n,system_mbox))=s,
    (ex(type(n,system_mbox))&next next false) chop
    (ex(save(n,y,system_mbox))&next next false) chop
    (ex(delete(n,system_mbox))&next next false),
    ex(empty_action)&next next false) chop
  ((n := n+1)&next next false)) chop
ex(quit(system_mbox))
```

p2:

```
((delete_flag(msg(x,system_mbox))=0) &
(sender(msg(x,system_mbox))=s) &
(open_flag(system_mbox)=1))
&
(ex(from(s,system_mbox))&next next false) chop
(ex(folders(system_mbox))&next next false) chop
(ex(type(x,system_mbox))&next next false) chop
(ex(save(x,y,system_mbox))&next next false) chop
(ex(delete(x,system_mbox))&next next false) chop
ex(quit(system_mbox))
```

p3:

```
(delete_flag(msg(x,system_mbox))=0) &
(sender(msg(x,system_mbox))=s) &
(open_flag(system_mbox)=1))
&
(ex(from(s,system_mbox))&next next false) chop
(ex(folders(system_mbox))&next next false) chop
(ex(type(x,system_mbox))&next next false) chop
(ex(delete(x,system_mbox))&next next false) chop
ex(quit(system_mbox))
```

p4:

```
((forall x : ((sender(msg(x,system_mbox))=s) ~~>
(delete_flag(msg(x,system_mbox))=0))) &
(open_flag(system_mbox)=1))
&
(ex(from(s,system_mbox))&next next false) chop
((n := 1)&next next false) chop
while(n < length(system_mbox),
  if(sender(msg(n,system_mbox))=s,
  ex(type(n,system_mbox))&next next false,
  ex(empty_action)&next next false) chop
((n := n+1)&next next false))
```

Die Menge der verwendeten Klassifikationskriterien mit ihrer numerischen Bewertung.

```
class_formula(a, subplan,
  [ global_var(x,integer),
global_var(mb,mbox),
global_var(y,file) ],
  (sometimes ex(save(msg(x,mb),y)) chop
  ex(delete(msg(x,mb))) chop
  ex(quit(mb))),subopt,0.2).
```

```
class_formula(c, subplan,
  [ global_var(mb,mbox) ],
  (sometimes ex(quit(mb))),opt,0.1).
```

```
class_formula(f, subplan,
  [ global_var(x,integer),
  global_var(mb,mbox) ],
  (sometimes ex(type(msg(x,mb))) chop
  ex(delete(msg(x,mb)))),opt,0.1).
```

```
class_formula(b, goal,
  [ global_var(xb,integer),
global_var(mb,mbox),
global_var(zb,sender) ],
  (exists mb:
  (exists zb:
  (sometimes(
  (forall xb:
  (((sender(msg(xb,mb))=zb) &
  (delete_flag(msg(xb,mb)) = 0) &
  (open_flag(yb)=1))
  ~~>
  (sometimes((read_flag(msg(xb,mb))=1))))))))),opt,0.3).
```

```
class_formula(d,goal,
  [ global_var(xb,integer),
    global_var(mb,mbox),
    global_var(zb,sender) ],
  (exists mb:
    (exists zb:
      (sometimes(
        (forall xb:
          (((sender(msg(xb,mb))=zb) &
            (delete_flag(msg(xb,mb)) = 0) &
            (open_flag(mb)=1))
          ~~>
            (sometimes((delete_flag(msg(xb,mb))=1))))))))),_,0.2).

class_formula(e,goal,
  [ global_var(xb,integer),
    global_var(mb,mbox),
    global_var(zb,sender) ],
  (exists mb:
    (exists zb:
      (sometimes(
        (forall xb:
          (((delete_flag(msg(xb,mb)) = 0) &
            (open_flag(mb)=1))
          ~~>
            (sometimes((read_flag(msg(xb,mb))=1))))))))),_,0.1).
```


Bibliographie

- [AAAI, 1986] *Proceedings of the 5th National Conference of the American Association for Artificial Intelligence*, Philadelphia, PA, August 1986.
- [AAAI, 1990] *Proceedings of the 8th National Conference of the American Association for Artificial Intelligence*, Boston, MA, August 1990. MIT Artificial Intelligence Laboratory, Massachusetts Institute of Technology, Cambridge, Massachusetts.
- [AAAI, 1991] *Proceedings of the 9th National Conference of the American Association for Artificial Intelligence*, Anaheim, CA, July 1991. MIT Artificial Intelligence Laboratory, Massachusetts Institute of Technology, Cambridge, Massachusetts.
- [AAAI, 1996] *Proceedings of the 13th National Conference of the American Association for Artificial Intelligence*, 1996.
- [Allen *et al.*, 1991] J.F. Allen, H.A. Kautz, R.N. Pelavin und J.D. Tenenber. *Reasoning About Plans*. Morgan Kaufmann, Los Altos, CA, 1991.
- [Allen und Hayes, 1985] J. Allen und P. J. Hayes. A commonsense theory of time. In *Proceedings of the 9th International Joint Conference on Artificial Intelligence*, pp 528–531, 1985.
- [Allen, 1984] J. Allen. Towards a general theory of action and time. *Artificial Intelligence*, 23:123–154, 1984.
- [Allen, 1991] J. Allen. Planning as temporal reasoning. In *Proceedings of the 2nd International Conference on Principles of Knowledge Representation and Reasoning*, 1991.
- [André und Rist, 1996] E. André und T. Rist. Coping with Temporal Constraints in Multimedia Presentation Planning. In AAAI [1996].
- [Appelt und Pollack, 1990] D.E. Appelt und M. Pollack. Weighted Abduction for Plan Ascription. Technical report, Artificial Intelligence Center and Center for the Study of Language and Information, SRI International, Menlo Park, California, 1990.

- [Ardissono *et al.*, 1994] L. Ardissono, L. Lesmo und D. Sestero. Updating the User Model on the Basis of the Recognition of the User's Plans. In Goodman *et al.* [1994], pp 5–17.
- [Ardissono und Sestero, 1996] Lilliana Ardissono und Dario Sestero. Using dynamic user models in the recognition of the plans of the user. *User Modeling and User-Adapted Interaction*, 5(2):157–190, 1996.
- [Ardissono, 1996] L. Ardissono. *Dynamic User Modeling and Plan Recognition in Dialogue*. PhD thesis, Università di Torino, 1996.
- [Bacchus *et al.*, 1992] F. Bacchus, A. Grove, J.Y. Halpern und D. Koller. From Statistics to Beliefs. In *Proceedings of the 10th National Conference of the American Association for Artificial Intelligence*, pp 602–608, San Jose, CA, July 1992. MIT Artificial Intelligence Laboratory, Massachusetts Institute of Technology, Cambridge, Massachusetts.
- [Bäckström und Sandewall, 1994] C. Bäckström und E. Sandewall, Hrsg. *Current Trends in AI Planning: Proceedings of the Second European Workshop on Planning*, Frontiers in Artificial Intelligence and Applications, Vadstena, Sweden, 1994. IOS Press.
- [Barès *et al.*, 1994] M. Barès, D. Canamero, J.-F. Delannoy und Y. Kodratoff. XPLANS: Case-Based Reasoning for Plan Recognition. *Applied Artificial Intelligence*, 8:617–643, 1994.
- [Bauer *et al.*, 1988] M. Bauer, G. Diewald, G. Merziger und I. Wellner. REPLAI: Ein System zur inkrementellen Intentionserkennung in Realwelt-Szenen. Memo 29, Universität des Saarlandes, FB Informatik, 1988.
- [Bauer *et al.*, 1991] M. Bauer, S. Biundo, D. Dengler, M. Hecking, J. Köhler und G. Merziger. PHI, Planbasierte Hilfesysteme. In R. Cunis A. Günter, Hrsg., *Beiträge zum 5. Workshop "Planen und Konfigurieren"*, pp 210–213. Labor für Künstliche Intelligenz, 1991.
- [Bauer *et al.*, 1993] M. Bauer, S. Biundo, D. Dengler, J. Koehler und G. Paul. PHI—A Logic-Based Tool for Intelligent Help Systems. In R. Bajcsy, Hrsg., *Proceedings of the 13th International Joint Conference on Artificial Intelligence*, pp 460–466, Chambéry, France, August 1993. Morgan Kaufmann Publishers.
- [Bauer *et al.*, 1996] M. Bauer, S. Biundo, D. Dengler, H. Feibel, J. Koehler und G. Paul. RAP – Reasoning About Plans: A Progress Report. In J. Sauer, A. Günter und J. Hertzberg, Hrsg., *Planen und Konfigurieren 96 – Beiträge zum PuK-96*, Nummer 3 von Proceedings in Artificial Intelligence, pp 193–204. infix, 1996.

- [Bauer und Paul, 1993] M. Bauer und G. Paul. Logic-based Plan Recognition for Intelligent Help Systems. In Bäckström und Sandewall [1994], pp 60–73.
- [Bauer, 1992a] M. Bauer. An Interval-based Temporal Logic in a Multivalued Setting. In D. Kapur, Hrsg., *Proceedings of the 11th International Conference on Automated Deduction*, Nummer 607 von Lecture Notes in Computer Science, pp 355–369, Saratoga Springs, NY, USA, 1992. Springer-Verlag.
- [Bauer, 1992b] M. Bauer. Implementation of Temporal Modalities in MVL. In J. Allen, M. Boddy, S. Hanks und N. Muscettola, Hrsg., *Workshop Notes of the AAAI-92 Workshop on Implementing Temporal Reasoning*, pp 14–23, San Jose, CA, USA, 1992.
- [Bauer, 1994a] M. Bauer. Integrating Probabilistic Reasoning into Plan Recognition. In Cohn [1994], pp 620–624.
- [Bauer, 1994b] M. Bauer. Quantitative Modeling of User Preferences for Plan Recognition. In Goodman et al. [1994], pp 73–78.
- [Bauer, 1995a] M. Bauer. A Dempster-Shafer Approach to Modeling Agent Preferences for Plan Recognition. *User Modeling and User-Adapted Interaction*, 5(3-4):317–348, 1995.
- [Bauer, 1995b] M. Bauer, Hrsg. *IJCAI 95 Workshop on The Next Generation of Plan Recognition Systems: Challenges for and Insight from Related Areas of AI (Working Notes)*, Montréal, Canada, 1995.
- [Bauer, 1996a] M. Bauer. Acquisition of User Preferences for Plan Recognition. In D. Chin, Hrsg., *Proceedings of the Fifth International Conference on User Modeling (UM96)*, pp 105–112, Kailua-Kona, HI, USA, 1996.
- [Bauer, 1996b] M. Bauer. Approximations for Decision Making in the Dempster-Shafer Theory of Evidence. In E. Horvitz und F. Jensen, Hrsg., *Proceedings of the 12th Conference on Uncertainty in Artificial Intelligence*, Portland, OR, USA, 1996.
- [Bauer, 1996c] M. Bauer. Justification of Plan Recognition Results. In W. Wahlster, Hrsg., *Proceedings of the 12th European Conference on Artificial Intelligence*, pp 647–651, Budapest, Hungary, 1996.
- [Benoit et al., 1988] J.W. Benoit, E.J. Dombroski, P.W. Jordan und S.J. Laskowski. Expert Systems for Multi-Agent Plan Recognition in Uncertain Environments (Extended Abstract). In McDermott et al. [1988].

- [Biundo *et al.*, 1992] S. Biundo, D. Dengler und J. Koehler. Deductive Planning and Plan Reuse in a Command Language Environment. In B. Neumann, Hrsg., *Proceedings of the 10th European Conference on Artificial Intelligence*, pp 628–632, Vienna, Austria, August 1992. Wiley.
- [Calabrese, 1987] P. Calabrese. An Algebraic Synthesis of the Foundations of Logic and Probability. *Information Sciences*, 42:187–237, 1987.
- [Calistri-Yeh, 1991] R.J. Calistri-Yeh. Utilizing user models to handle ambiguity and misconceptions in robust plan recognition. *User Modeling and User-Adapted Interaction*, 2(1-2), 1991.
- [Calistri, 1990] R.J. Calistri. *Classifying and Detecting Plan-Based Misconceptions for Robust Plan Recognition*. PhD thesis, Dept. of Computer Science, Brown University, RI, 1990.
- [Carberry, 1990a] S. Carberry. Incorporating Default Inferences into Plan Recognition. In AAAI [1990], pp 471–478.
- [Carberry, 1990b] S. Carberry. A model of plan recognition that facilitates default inferences. In *Proceedings of the Second International Workshop on User Modeling (UM90)*, Honolulu, Hawaii, 1990.
- [Carberry, 1990c] S. Carberry. *Plan Recognition in Natural Language Dialogue*. MIT Press, Cambridge, MA, 1990.
- [Charniak und Goldman, 1989] E. Charniak und R. Goldman. A Semantics for Probabilistic Quantifier-Free First-Order Languages, with Particular Application to Story Understanding. In IJCAI [1989], pp 1074–1079.
- [Charniak und Goldman, 1991] E. Charniak und R. Goldman. A probabilistic model of plan recognition. In AAAI [1991], pp 160–165.
- [Charniak und Goldman, 1993] E. Charniak und R.P. Goldman. A Bayesian model of plan recognition. *Artificial Intelligence*, 64(1):53–79, 1993.
- [Charniak, 1986] E. Charniak. A neat theory of marker passing. In AAAI [1986], pp 584–589.
- [Charniak, 1991] E. Charniak. Bayesian Networks without Tears. *The AI Magazine*, 12(4):50–63, 1991.
- [Chellas, 1980] B.F. Chellas. *Modal Logic: An Introduction*. Cambridge University Press, Cambridge, 1980.
- [Chvátal, 1983] V. Chvátal. *Linear Programming*. Freeman, 1983.

- [Cohn, 1994] T. Cohn, Hrsg. *Proceedings of the 11th European Conference on Artificial Intelligence*, Amsterdam, Netherlands, August 1994. Wiley.
- [de Kleer, 1986a] J. de Kleer. An assumption-based truth maintenance system. *Artificial Intelligence*, 28:127–162, 1986.
- [de Kleer, 1986b] J. de Kleer. An assumption-based truth maintenance system. *Artificial Intelligence*, 28:127–162, 1986.
- [Dempster, 1967] A.P. Dempster. Upper and lower probabilities induced by a multi-valued mapping. *Annals of Mathematical Statistics*, 38:325–339, 1967.
- [Dengler, 1994] D. Dengler. An Adaptive Deductive Planning System. In Cohn [1994], pp 610–614.
- [Devanbu und Litman, 1991] P. Devanbu und D. Litman. Plan-Based Terminological Reasoning. In J.A. Allen, R. Fikes und E. Sandewall, Hrsg., *Principles of Knowledge Representation and Reasoning: Proceedings of the 2nd International Conference*, pp 128–138, Cambridge, MA, April 1991. Morgan Kaufmann Publishers.
- [Dietterich und Michalski, 1983] T. Dietterich und R. Michalski. Machine Learning—An Artificial Intelligence Approach. In Michalski et al. [1983], Kapitel 3.
- [Dubois und Prade, 1985] D. Dubois und H. Prade. A Note on Measures of Specificity for Fuzzy Sets. *Int. J. Gen. Syst.*, 10:279–283, 1985.
- [Dubois und Prade, 1991] D. Dubois und H. Prade. Conditioning, Non-monotonic Logic and Non-standard Uncertainty Models. In Goodman et al. [1991], pp 115–158.
- [Dubois und Prade, 1992] D. Dubois und H. Prade. Evidence, Knowledge, and Belief Functions. *International Journal of Approximate Reasoning*, 6:295–319, 1992.
- [Elzer et al., 1994] S. Elzer, J. Chu-Carroll und S. Carberry. Recognizing and Utilizing User Preferences in Collaborative Consultation Dialogues. In Goodman et al. [1994], pp 19–24.
- [Enderton, 1972] H. B. Enderton. *A Mathematical Introduction to Logic*. Academic Press, New York, 1972.
- [Feibel, 1994] H. Feibel. IGLOO 1.0 – Eine grafikunterstützte Beweisentwicklungsumgebung, Benutzerhandbuch. Document D-94-08, DFKI, 1994.
- [Feibel, 1995] H. Feibel. IGLOO – A Graphic Supported Proof Development Environment. In Peter H. Schmitt, Hrsg., *Logik in der Informatik, 3. Jahrestagung der GI-Fachgruppe 0.1.6*, Interner Bericht 13/95, pp 55–64. Universität Karlsruhe, Fakultät für Informatik, 1995.

- [Friedman und Goldszmidt, 1996] N. Friedman und M. Goldszmidt. Building Classifiers using Bayesian Networks. In AAAI [1996].
- [Goldman und Charniak, 1988] R. Goldman und E. Charniak. A Probabilistic ATMS for Plan Recognition. In McDermott et al. [1988].
- [Goodman *et al.*, 1991] I.R. Goodman, M.M. Gupta, H.T. Nguyen und G.S. Rogers, Hrsg. *Conditional Logic in Expert Systems*. Elsevier, 1991.
- [Goodman *et al.*, 1994] B. Goodman, A. Kobsa und D. Litman, Hrsg. *Proceedings of the Fourth International Conference on User Modeling (UM94)*, Hyannis, MA, USA, 1994.
- [Goodman und Litman, 1992] B.A. Goodman und D.J. Litman. On the Interaction between Plan Recognition and Intelligent Interfaces. *User Modeling and User-Adapted Interaction*, 2(1-2):83–116, 1992.
- [Goodman und Nguyen, 1988] I.R. Goodman und H.T. Nguyen. Conditional Objects and the Modeling of Uncertainties. In M.M. Gupta und T. Yamakawa, Hrsg., *Fuzzy Computing – Theory, Hardware, and Applications*, pp 119–138. North-Holland, 1988.
- [Gordon und Shortliffe, 1985] J. Gordon und E.H. Shortliffe. A Method for Managing Evidential Reasoning in a Hierarchical Hypothesis Space. *Artificial Intelligence*, 26:323–357, 1985.
- [Grätzer, 1978] G. Grätzer. *General Lattice Theory*, volume 52 of *Mathematische Reihe*. Birkhäuser, 1978.
- [Guan und Bell, 1991] J. Guan und D. Bell. *Evidence Theory and its Applications*, volume 1. Elsevier, 1991.
- [Halpern und Fagin, 1992] J.Y. Halpern und R. Fagin. Two views of belief: belief as generalized probability and belief as evidence. *Artificial Intelligence*, 54:275–317, 1992.
- [Harper *et al.*, 1981] W.L. Harper, R. Stalnaker und G. Pearce, Hrsg. *Conditionals, Belief, Decision, Chance and Time*. Reidel, Dordrecht, 1981.
- [Heckerman, 1995] D. Heckerman. A Bayesian Approach to Learning Causal Networks. Technical Report MSR-TR-95-04, Microsoft Research, 1995.
- [Hecking *et al.*, 1988] M. Hecking, C. Kemke, E. Nessen, D. Dengler, M. Gutmann und G. Hecktor. The SINIX Consultant - a Progress Report. Memo 28, Universität des Saarlandes, FB Informatik, 1988.

- [Hecking, 1993] M. Hecking. *Eine logische Behandlung der verteilten und mehrstufigen Planerkennung*. Verlag Shaker, Aachen, 1993.
- [Heinsohn, 1986] J. Heinsohn. Weiterentwicklung und Implementierung eines Inferenzmechanismus auf der Basis von Belief-Funktionen. Master's thesis, TU Braunschweig, 1986.
- [Heinsohn, 1993] J. Heinsohn. *ALCP: Ein hybrider Ansatz zur Modellierung von Unsicherheit in terminologischen Logiken*, volume 55 of *DISKI*. infix, Sankt Augustin, 1993.
- [Hong, 1993] J. Hong. Plan recognition on the basis of structural and temporal constraints. In Bäckström und Sandewall [1994], pp 131–144.
- [Hong, 1994] J. Hong. Constraint satisfaction as an approach to plan recognition. In Goodman et al. [1994], S. 217.
- [Huber und Durfee, 1992] M. Huber und E. Durfee. Plan Recognition for Real-World Autonomous Robots. In *Working Notes: Applications of Artificial Intelligence to Real-World Autonomous Mobile Robots*, AAAI Fall Symposium, pp 68–75, 1992.
- [Huber und Durfee, 1993] M. Huber und E. Durfee. Observational Uncertainty in Plan Recognition Among Interacting Robots. In *Workshop Notes of the IJCAI93 Workshop on Dynamically Interacting Robots*, pp 68–75, 1993.
- [IJCAI, 1987] *Proceedings of the 10th International Joint Conference on Artificial Intelligence*, Milan, Italy, August 1987. Morgan Kaufmann Publishers.
- [IJCAI, 1989] *Proceedings of the 11th International Joint Conference on Artificial Intelligence*, Detroit, MI, August 1989. Morgan Kaufmann Publishers.
- [JAPPR, 1992] International Journal of Approximate Reasoning: Special Issue on Belief Functions. volume 6(3), Elsevier, May 1992.
- [Kass und Finin, 1991] R. Kass und T. Finin. General User Modeling: A Facility to Support Intelligent Interaction. In J.W. Sullivan und S.W. Tyler, Hrsg., *Intelligent User Interfaces*, Kapitel 6. acm Press, 1991.
- [Kautz und Allen, 1986] H. Kautz und J. Allen. Generalized Plan Recognition. In AAAI [1986], pp 32–37.
- [Kautz, 1987] H. Kautz. *A Formal Theory of Plan Recognition*. PhD thesis, University of Rochester, 1987.
- [Kautz, 1991] H. Kautz. *A Formal Theory of Plan Recognition and its Implementation*, Kapitel 2. In Allen et al. [1991], 1991.

- [Koehler, 1994] J. Koehler. *Wiederverwendung von Plänen in deduktiven Planungssystemen*, volume 65 of *DISKI. infix*, Sankt Augustin, 1994.
- [Kozierok und Maes, 1993] R. Kozierok und P. Maes. A Learning Interface Agent for Scheduling Meetings. In W. Gray, W. Hefley und D. Murray, Hrsg., *Proceedings of the 1993 International Workshop on Intelligent User Interfaces*, pp 81–88, Orlando, Fl, USA, 1993.
- [Kruse *et al.*, 1991] R. Kruse, E. Schwecke und J. Heinsohn. *Uncertainty and Vagueness in Knowledge-Based Systems*. Springer-Verlag, Berlin, Heidelberg, New York, 1991.
- [Kyburg, 1987] H. E. Kyburg. Bayesian and Non-Bayesian Evidential Updating. *Artificial Intelligence*, 31:271–284, 1987.
- [Lemmer und Kyburg, 1991] J. F. Lemmer und H. E. Kyburg. Conditions for the Existence of Belief Functions Corresponding to Intervals of Belief. In *AAAI [1991]*.
- [Lesh und Etzioni, 1995a] N. Lesh und E. Etzioni. A Sound and Fast Goal Recognizer. In C. Mellish, Hrsg., *Proceedings of the 14th International Joint Conference on Artificial Intelligence*, pp 1704–1710, Montréal, Canada, August 1995. Morgan Kaufmann Publishers.
- [Lesh und Etzioni, 1995b] N. Lesh und E. Etzioni. Insights from Machine Learning for Plan Recognition. In Bauer [1995b], pp 78–83.
- [Lewis, 1981] D. Lewis. Probabilities of Conditionals and Conditional Probabilities. In Harper *et al.* [1981], pp 129–150.
- [Lowrance *et al.*, 1986] J.D. Lowrance, T.D. Garvey und T.M. Strat. A Framework for Evidential-Reasoning Systems. In *AAAI [1986]*, pp 896–903.
- [Maes und Kozierok, 1993] P. Maes und R. Kozierok. Learning Interface Agents. In *Proceedings of the 11th National Conference of the American Association for Artificial Intelligence*, pp 459–465. MIT Artificial Intelligence Laboratory, Massachusetts Institute of Technology, Cambridge, Massachusetts, 1993.
- [Maes, 1994] P. Maes. Agents that Reduce Work and Information Overload. *Communications of the ACM*, 37(7):31–40, 1994.
- [Mayfield, 1992] J. Mayfield. Controlling Inference in Plan Recognition. *User Modeling and User-Adapted Interaction*, 2(1-2):55–82, 1992.
- [McCarthy, 1980] J. McCarthy. Circumscription - a form of non-monotonic reasoning. *Artificial Intelligence*, 13:27–39, 1980.

- [McDermott *et al.*, 1988] D. McDermott, L. Birnbaum, J. Maier, R. Wilensky, S. Williams und D. Chubb, Hrsg. *Proceedings of the AAAI-88 Workshop on Plan Recognition*, St. Paul, MI, 1988.
- [Michalski *et al.*, 1983] R. Michalski, J. Carbonell und T. Mitchell, Hrsg. *Machine Learning—An Artificial Intelligence Approach*. Springer-Verlag, Berlin, Heidelberg, New York, 1983.
- [Myers, 1989] J.K. Myers. An Assumption-Based Plan Inference System for Conversation Understanding. In *WGNL Meeting of the IPSJ*, pp 73–80, Okinawa, Japan, 1989.
- [Myers, 1990] J.K. Myers. A Project Report on NP: an Assumption-based NL Plan Inference System that uses Feature Structures. In *Proceedings of the 13th International Conference on Computational Linguistics*, pp 428–430, Helsinki, Finland, 1990.
- [Myers, 1991] J.K. Myers. Plan Inference with Probabilistic-Outcome Actions. In *Conference Proceedings of the Information Processing Society of Japan*, volume 3, pp 168–169, 1991.
- [Nguyen und Rogers, 1991] H.T. Nguyen und G.S. Rogers. Conditioning Operators in a Logic of Conditionals. In Goodman *et al.* [1991], pp 159–179.
- [Nguyen, 1992] H.T. Nguyen. Algebraic structure of conditional reasoning. In B.M. Ayyub, M.M. Gupta und L.N. Kanal, Hrsg., *Analysis and Management of Uncertainty: Theory and Applications*, Nummer 13 von Machine Intelligence and Pattern Recognition, pp 43–53. Elsevier, 1992.
- [Orponen, 1990] P. Orponen. Dempster's Rule of Combination is # P-complete. *Artificial Intelligence*, 44:245–253, 1990.
- [Paris, 1988] C.L. Paris. Tailoring Object Descriptions to a User's Level of Expertise. *Computational Linguistics*, 14(3):64–78, 1988.
- [Paul, 1993] G. Paul. Approaches to Abductive Reasoning—An Overview. *Artificial Intelligence Review*, 7:109–152, 1993.
- [Pearl, 1988] J. Pearl. *Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Reasoning*. Morgan Kaufmann, Los Altos, CA, 1988.
- [Quinlan, 1983] J.R. Quinlan. Learning Efficient Classification Procedures and Their Application to Chess End Games. In Michalski *et al.* [1983], Kapitel 15.
- [Quinlan, 1986a] J.R. Quinlan. Induction of Decision Trees. *Machine Learning*, 1:81–106, 1986.

- [Quinlan, 1986b] J.R. Quinlan. The Effect of Noise on Concept Learning. In *Machine Learning—An Artificial Intelligence Approach*, volume II, Kapitel 6. Morgan Kaufmann Publishers, Los Altos, California, 1986.
- [Quinlan, 1990] J.R. Quinlan. Machine Learning—An Artificial Intelligence Approach. In *Probabilistic Decision Trees*, volume III, Kapitel 5. Morgan Kaufmann Publishers, Los Altos, California, 1990.
- [Quinlan, 1993] J.R. Quinlan. *C4.5: Programs for Machine Learning*. Morgan Kaufmann, Los Altos, CA, 1993.
- [Quinlan, 1996] J.R. Quinlan. Improved Use of Continuous Attributes in C4.5. *Journal of Artificial Intelligence Research*, 4:77–90, 1996.
- [Raskutti und Zukerman, 1991a] B. Raskutti und I. Zukerman. Generation and Selection of Likely Interpretations during Plan Recognition in Task-Oriented Consultation Systems. *User Modeling and User-Adapted Interaction*, 1:323–353, 1991.
- [Raskutti und Zukerman, 1991b] B. Raskutti und I. Zukerman. Handling Uncertainty during Plan Recognition in Task-Oriented Consultation Systems. In B. D'Ambrosio, P. Smets und P. Bonissone, Hrsg., *Proceedings of the Seventh Conference on Uncertainty in Artificial Intelligence*, pp 308–315, University of Los Angeles, CA, 1991.
- [Reiter, 1980] R. Reiter. A logic for default reasoning. *Artificial Intelligence*, 13(2):81–132, 1980.
- [Retz-Schmidt, 1988] G. Retz-Schmidt. A REPLAI of SOCCER: Recognizing Intentions in the Domain of Soccer Games. In Yves Kodratoff, Hrsg., *Proceedings of the 8th European Conference on Artificial Intelligence*, pp 455–457, Munich, Germany, August 1988. Pitman.
- [Retz-Schmidt, 1991] G. Retz-Schmidt. Recognizing Intentions, Interactions and Causes of Plan Failures. *User Modeling and User-Adapted Interaction*, 1:173–202, 1991.
- [Rosner und Pnueli, 1986] R. Rosner und A. Pnueli. A choppy logic. In *Proceedings of the Symposium on Logic in Computer Science*, pp 306–313, June 1986.
- [Ruspini *et al.*, 1992] E.H. Ruspini, J.D. Lowrance und T.M. Strat. Understanding Evidential Reasoning. *International Journal of Approximate Reasoning*, 6:401–424, 1992.
- [Ruspini, 1986] E.H. Ruspini. The Logical Foundations of Evidential Reasoning. Technical Note 408, SRI International, December 1986.

- [Ruspini, 1987] E.H. Ruspini. Epistemic Logics, Probability, and the Calculus of Evidence. In IJCAI [1987], pp 924–931.
- [Schay, 1968] G. Schay. An algebra of conditional events. *Journal of Mathematical Analysis and Applications*, 24:334–344, 1968.
- [Schmidt *et al.*, 1978] C.F. Schmidt, N.S. Sridharan und J.L. Goodson. The Plan Recognition Problem: An Intersection of Psychology and Artificial Intelligence. *Artificial Intelligence*, 11:45–82, 1978.
- [Shafer, 1976] G. Shafer. *A Mathematical Theory of Evidence*. Princeton University Press, Princeton, NJ, 1976.
- [Shafer, 1992] G. Shafer. Rejoinders to Comments on “Perspectives on the Theory and Practice of Belief Functions”. *International Journal of Approximate Reasoning*, 6:445–480, 1992.
- [Shanahan, 1989] M. Shanahan. Prediction is Deduction but Explanation is Abduction. In IJCAI [1989], pp 1055–1060.
- [Shavlik und Dietterich, 1990] J.W. Shavlik und T.G. Dietterich, Hrsg. *Readings in Machine Learning*. Morgan Kaufmann Publishers, Los Altos, California, 1990.
- [Shortliffe und Buchanan, 1975] E.H. Shortliffe und B.G. Buchanan. A Model of Inexact Reasoning in Medicine. *Math. Biosci.*, 23:351–379, 1975.
- [Shortliffe, 1976] E.H. Shortliffe. *Computer-Based medical Consultations: MYCIN*. Elsevier, 1976.
- [Smets, 1988] P. Smets. Belief Functions versus Probability Functions. In B. Bouchon, L. Saitta und R. Yager, Hrsg., *Uncertainty and Intelligent Systems*, volume 313 of *Lecture Notes in Computer Science*, pp 17–24, 1988.
- [Spies, 1991] M. Spies. Combination of Evidence with Conditional Objects and its Application to Cognitive Modeling. In Goodman et al. [1991], pp 181–209.
- [Stanfill und Waltz, 1986] C. Stanfill und D. Waltz. Toward Memory-Based Reasoning. *Communications of the ACM*, 29(12):1213–1228, 1986.
- [Strat, 1987] T.M. Strat. The Generation of Explanations within Evidential Reasoning Systems. In IJCAI [1987], pp 1097–1104.
- [Tessem, 1993] B. Tessem. Approximations for efficient computation in the theory of evidence. *Artificial Intelligence*, 61:315–329, 1993.
- [Thies und Berger, 1992] M.A. Thies und F. Berger. Plan-Based Graphical Help in Object-Oriented User Interfaces. In *Proceedings of the International Workshop on Advanced Visual Interfaces*, pp 455–457, Rome, Italy, 1992.

- [Thies, 1994] M. Thies. *Planbasierte Hilfeverfahren für direkt-manipulative Systeme*. Nummer 67 von DISKI. 1994.
- [Vilain, 1990] M. Vilain. Getting Serious about Parsing Plans: a Grammatical Analysis of Plan Recognition. In AAI [1990], pp 190–197.
- [Voorbraak, 1989] F. Voorbraak. A Computationally Efficient Approximation of Dempster-Shafer Theory. *International Journal of Man-Machine Studies*, 30:525–536, 1989.
- [Wærn, 1994] A. Wærn. Plan Inference for a Purpose. In Goodman et al. [1994], pp 93–98.
- [Wahlster et al., 1993] W. Wahlster, E. Andre, W. Finkler, H.J. Profitlich und T. Rist. Plan-Based Integration of Natural Language and Graphics Generation. *Artificial Intelligence*, 63:387–427, 1993.
- [Wahlster und Kobsa, 1986] W. Wahlster und A. Kobsa. Dialog-Based User Models. In G. Ferrari, Hrsg., *Proceedings of the IEEE 74 (7)*, pp 984–990, 1986.
- [Weida und Litman, 1992] R. Weida und D. Litman. Terminological Reasoning with Constraint Networks and an Application to Plan Recognition. In B. Nebel, W. Swartout und C. Rich, Hrsg., *Principles of Knowledge Representation and Reasoning: Proceedings of the 3rd International Conference*, pp 282–293, Cambridge, MA, October 1992. Morgan Kaufmann Publishers.
- [Weida und Litman, 1994] R. Weida und D. Litman. Subsumption and Recognition of Heterogeneous Constraint Networks. In *Proceedings of the Tenth Conference on Artificial Intelligence for Applications*, pp 381–388. The Computer Society of the IEEE, 1994.
- [Weida, 1995] R. Weida. Knowledge Representation for Plan Recognition. In Bauer [1995b], pp 119–123.
- [Wilensky, 1978] R. Wilensky. Why John married Mary: Understanding Stories Involving Recurring Goals. *Cognitive Science*, 2:235–266, 1978.
- [Wills, 1990] L. Wills. Automated Program Recognition: A Feasibility Demonstration. *Artificial Intelligence*, 45:113–171, 1990.
- [Wilson, 1993] N. Wilson. Decision-Making with Belief Functions and Pignistic Probabilities. In M. Clarke, R. Kruse und S. Moral, Hrsg., *Proceedings of the European Conference on Symbolic and Quantitative Approaches to Reasoning and Uncertainty*, Nummer 747 von Lecture Notes in Computer Science, pp 364–371, Granada, Spain, 1993. Springer-Verlag.

- [Wobcke, 1988] W. Wobcke. A Logical Theory of Plan Recognition. In McDermott et al. [1988].
- [Wong, 1981] D. Wong. Language Comprehension in a Problem Solver. In *Proceedings of the 7th International Joint Conference on Artificial Intelligence*, pp 7–12, Vancouver, Canada, August 1981.
- [Wu, 1991] D. Wu. Active Acquisition of User Models: Implications for Decision-theoretic Planning and Plan Recognition. *User Modeling and User-Adapted Interaction*, 1:149–172, 1991.
- [Yen, 1986] J. Yen. A Reasoning Model Based on an Extended Dempster-Shafer Theory. In AAAI [1986], pp 125–131.
- [Yen, 1989] J. Yen. GERTIS: A Dempster-Shafer Approach to Diagnosing Hierarchical Hypotheses. *Communications of the ACM*, 32(5):573–585, 1989.
- [Yoshida et al., 1994] K. Yoshida, H. Motoda und N. Indurkha. Graph-Based Induction as a Unified Learning Framework. *Applied Artificial Intelligence*, 4:297–316, 1994.
- [Yoshida und Motoda, 1995] K. Yoshida und H. Motoda. CLIP: concept learning from inference patterns. *Artificial Intelligence*, 75:63–92, 1995.