

Institut für Parallele und Verteilte Systeme
Universität Stuttgart
Universitätsstraße 38
D-70569 Stuttgart

Diplomarbeit Nr. 3205

**Probabilistisches Schließen mit
Subjektiver-Logik in
prozessbasierten,
kontextbezogenen Anwendungen**

Michael Trunner

Studiengang: Informatik
Prüfer: Prof. Dr. K. Rothermel
Betreuer: Dipl.-Inf. Hannes Wolf

begonnen am: 1. Juni 2011
beendet am: 1. Dezember 2011

CR-Klassifikation: F.4.1, I.2.3

Inhaltsverzeichnis

1	Einleitung	9
2	FlowCon und andere Systeme	11
2.1	FlowCon	11
2.2	Abgrenzung zu anderen Systemen	15
2.3	Zusammenfassung	17
3	Unsicherheitsmodelle	19
3.1	Einleitung	19
3.2	Anforderungen an ein Unsicherheitsmodell	21
3.3	Dempster-Shafer-Theorie	22
3.4	Vier-Wertige-Logik	30
3.5	Subjektive-Logik	33
3.6	Zusammenfassung	50
4	Hyper-FlowCon	53
4.1	Integration der Subjektiven-Logik	53
4.2	Verschiedene Eingabe-Verarbeitungen	57
4.3	Verschiedene Condition-Evaluators	59
4.4	Zusammenfassung	63
5	Simulation und Auswertung	65
5.1	Aufbau	65
5.2	Versuchsübersicht	67
5.3	Auswertung der Ergebnisse	68
5.4	Zusammenfassung	86
6	Zusammenfassung und Ausblick	89
	Index	93
	Literatur	97

Abbildungsverzeichnis

2.1	Ein <i>Flow</i> -Modell [WHR10]	14
2.2	Aufbau von FlowCon [WHR10]	15
3.1	Glaubensintervall	24
3.2	Vier-Wertige-Logik	31
3.3	Zusammenhang zwischen Glaubensintervall und <i>Binomial-Opinion</i>	35
3.4	<i>Opinion-Simplex</i> mit einer eingezeichneten <i>Binomial-Opinion</i>	37
3.5	<i>Opinion-Simplex</i> für eine <i>Multinomial-Opinion</i>	39
3.6	Projektion des <i>Opinion-Dreiecks</i> [Jøs10]	46
3.7	Unsicherheitsmaximierung einer dogmatischen <i>Opinion</i> [Jøs10]	47
4.1	Aufbau von Hyper-FlowCon	55
4.2	Designierte Werte des Four-Condition-Evaluators	62
5.1	Erkennungsrate ohne die Unterstützung von FlowCon oder Hyper-FlowCon	68
5.2	Erkennungsrate von FlowCon	69
5.3	Erkennungsrate von Hyper-FlowCon mit SUBCE	71
5.4	Erkennungsrate von Hyper-FlowCon mit BINCE	71
5.5	<i>Flow</i> -Sicherheit beim SUBCE	72
5.6	Mittlere Sicherheit der Eingabe bei einer vollständigen Verteilung	72
5.7	Erkennungsrate von Hyper-FlowCon mit FOURCE	74
5.8	Erkennungsrate des SUBCE bei einer reduzierten Eingabe	75
5.9	<i>Flow</i> -Sicherheit des SUBCE bei einer reduzierten Eingabe	75
5.10	Erkennungsrate des BINCE bei einem Vertrauen von 60%	77
5.11	Erkennungsrate des SUBCE bei einem Vertrauen von 60%	78
5.12	<i>Flow</i> -Sicherheit beim SUBCE mit einem Vertrauen von 60%	79
5.13	Erkennungsrate des FOURCE bei einem Vertrauen von 60%	79
5.14	Erkennungsrate des SUBCE mit einem adaptiven Schwellwert s von 25%	81
5.15	Erkennungsrate des SUBCE mit einem adaptiven Schwellwert s von 30%	81
5.16	Erkennungsrate des SUBCE mit $s = 28\%$ und 60% Vertrauen	83
5.17	<i>Flow</i> -Sicherheit beim SUBCE mit $s = 28\%$ und 60% Vertrauen	83
5.18	Erkennungsrate des FOURCE mit $s = 28\%$ und 60% Vertrauen	84
5.19	Erkennungsrate des SUBCE, $s = 28\%$, 60% Vertrauen, reduzierte Eingabe	85
5.20	SUBCE im Vergleich zu FlowCon bei einer Grundwahrheit von 45%	88
5.21	Endergebnisse im Vergleich zu FlowCon bei einer Grundwahrheit von 45%	88

Tabellenverzeichnis

3.1	Die vier Wetten des Ellsbergs-Paradoxons	20
3.2	Schnittmengentabelle für m_1 und m_2 . In den Klammern befinden sich die jeweils unskalierten Werte.	26
3.3	Schnittmengentabelle für m_3 und m_4 . In den Klammern befinden sich die jeweils unskalierten Werte.	27
3.4	Werte der Vier-Wertigen-Logik [Bel77]	30
3.5	Operatoren der Vier-Wertigen-Logik [Tsoo2]	31
3.6	Die verschiedenen Klassen von <i>Opinions</i> und ihre zugehörigen Äquivalente.	35
3.7	<i>Binomial-Opinions</i> in verschiedenen Notationen [Jøs10]	43
3.8	Verschiedene Operatoren der Subjektiven-Logik [Jøs10]	43
3.9	Übersicht der Unsicherheitsmodelle und der erfüllten Anforderungen	51
4.1	Bestimmung der Werte der Vier-Wertigen-Logik	62
4.2	Interpretation der Vier-Wertigen-Logik für die Transitionsbedingungen	63
4.3	Zusammenfassung der Änderungen an FlowCon	64
5.1	Übersicht der durchgeführten Versuche und Ergebnisse	67
5.2	Erkennungsrate von FlowCon	69
5.3	Erkennungsrate des SUBCE bei einem Vertrauen von 60%	78
5.4	Erkennungsrate des SUBCE mit $s = 28\%$ und 60% Vertrauen	84
5.5	Erkennungsrate des FourCE mit $s = 28\%$ und 60% Vertrauen	84
5.6	Erkennungsrate des SUBCE, $s = 28\%$, 60% Vertrauen, reduzierte Eingabe	85

1 Einleitung

Das Themengebiet der Kontextinformationen ist in den letzten Jahren ein immer größerer Forschungsbereich der Informatik geworden. Aufgrund der technischen Entwicklung von Mobilgeräten hat sich die Definition des Begriffes Kontext erweitert. Ursprünglich bestand Kontext hauptsächlich aus einer Ortsangabe. Heute hingegen sollen Kontextinformationen zusätzlich auch die Aktivitäten und persönlichen Vorhaben des Benutzers erfassen und beschreiben, damit eine entsprechende Anpassung des kontextbezogenen Systems stattfinden kann. Diese neuen Kontextinformationen erweitern natürlich die Möglichkeiten und Einsatzgebiete.

Eines dieser neuen Einsatzgebiete ist das Geschäftsprozessmanagement, welches sich zu einer der wichtigsten Informations-Technologien für Unternehmen entwickelt hat. Es wird primär dazu eingesetzt die Produktivität der Abläufe und damit auch der Mitarbeiter zu erhöhen. Um dies zu erreichen wird der Mitarbeiter im steigenden Maß in den Prozess zur Strukturierung der Arbeitsabläufe miteinbezogen. Dadurch entsteht allerdings häufig die Notwendigkeit, dass der Mitarbeiter mit dem Prozessmanagementsystem interagieren muss. Dieser Vorgang lenkt von der Arbeit ab und senkt damit die Produktivität, welche es eigentlich zu steigern gilt. Um die erforderliche Interaktion auf ein Minimum zu reduzieren, wird häufig versucht die Aktivitäten des Mitarbeiters bzw. des Benutzers durch die vorhandenen Kontextinformationen zu bestimmen.

Die Erfassung solcher Kontextinformationen ist immer mit Unsicherheit behaftet und daher als direkte Eingabe in ein Prozessmanagementsystem ungeeignet. Bei festen Umgebungen, wie sie beispielsweise an Fertigungsstraßen gegeben sind, werden die Systeme der Kontexterfassung meist speziell für die bestehenden Rahmenbedingungen optimiert. In dynamischen Umgebungen der restlichen Welt ist dies aber – wenn überhaupt – nur bedingt möglich.

Im Rahmen des EU-Projekts ALLOW [Her+08] sind kürzlich Methoden und Systeme entwickelt worden, welche eine robuste Ausführung von prozessbasierten und kontextbezogenen Anwendungen dennoch erlauben. Eines dieser Systeme ist FlowCon [WHR10]. Bisher verwendet es zur Darstellung unsicherer Informationen, sowohl intern während der Verarbeitung, als auch extern als Ergebnis, die probabilistische Wahrscheinlichkeitstheorie. Zur Aufarbeitung der unsicheren Kontextinformationen verwendet FlowCon das probabilistische Schließen mit Bayes'schen Netzen. Diese Netze bestimmen die A-priori-Wahrscheinlichkeit der verschiedenen möglichen Ereignisse, wodurch die Verwendbarkeit und Qualität der Kontextinformationen gesteigert werden kann.

Diese Diplomarbeit befasst sich damit, inwieweit die Wahl eines geeigneten Unsicherheitsmodells Auswirkung auf die Leistungsfähigkeit des bestehenden Ansatzes von FlowCon hat. Zu diesem Zweck werden drei verschiedene Unsicherheitsmodelle untersucht. Zum besseren Vergleich dieser Modelle werden Anforderungen bzw. Kriterien aufgestellt, die ein Unsicherheitsmodell zur Integration in FlowCon aufweisen muss.

Untersucht werden die Dempster-Shafer-Theorie, die Vier-Wertige-Logik von Belnap sowie die Subjektive-Logik, hinsichtlich der Anwendung als Unsicherheitsmodell für FlowCon. Die Subjektive-Logik ist eine Erweiterung der Bayes'schen Wahrscheinlichkeitstheorie, welche neben der Unsicherheit des Betrachters, auch dessen Vorwissen bei der Schlussfolgerung mit in Betracht zieht.

Gliederung

Diese Arbeit besteht aus fünf weiteren Kapiteln und ist wie folgt gegliedert:

Kapitel 2 – FlowCon und andere Systeme befasst sich mit den in dieser Diplomarbeit notwendigen Grundlagen von FlowCon. Ebenso findet eine Abgrenzung von FlowCon zu anderen ähnlichen Arbeiten statt.

Kapitel 3 – Unsicherheitsmodelle erläutert die theoretischen Grundlagen dieser Arbeit. Im Detail werden hier die Unsicherheitsmodelle der Dempster-Shafer-Theorie, der Vier-Wertigen-Logik sowie die Subjektive-Logik näher beleuchtet und auf Tauglichkeit zur Anwendung überprüft. Hierzu werden Anforderungen aufgestellt, welche die Überprüfung erleichtern.

Kapitel 4 – Hyper-FlowCon erörtert die Erweiterung von FlowCon durch die in dem vorherigen Kapitel betrachteten Unsicherheitsmodelle. Des Weiteren wird auf die neuen Eigenschaften und Möglichkeiten eingegangen, welche sich aus der Erweiterung ergeben.

Kapitel 5 – Simulation und Auswertung beschreibt die durchgeführten Versuche und beleuchtet deren Ergebnisse. Anschließend werden die, neben den erzielten Verbesserungen, aufgetretenen Probleme näher analysiert und deren Lösungsansätze validiert.

Kapitel 6 – Zusammenfassung und Ausblick fasst die Ergebnisse dieser Arbeit zusammen und stellt Anknüpfungspunkte für weitere Arbeiten vor.

2 FlowCon und andere Systeme

Der erste Abschnitt dieses Kapitels befasst sich mit FlowCon. FlowCon ist ein Kontextmanager zur automatischen Erfassung von menschlichen Arbeitstätigkeiten. Die Leistungsfähigkeit von FlowCon wurde in der Altenpflege evaluiert und getestet. Dabei konnten die dortigen Tätigkeiten des Pflegepersonals durch den Einsatz von FlowCon robuster erfasst werden als zuvor. Um dies zu ermöglichen wertet FlowCon die Struktur der Prozesse sowie die Arbeitsabläufe des Pflegepersonals aus.

Im zweiten Teil des Kapitels werden andere Systeme mit ähnlichem Hintergrund vorgestellt und kurz gegen FlowCon abgegrenzt. Diese befassen sich teilweise ebenfalls mit der automatisierten Betreuung von älteren Mitmenschen oder handeln primär von Kontextverarbeitung und Workflows.

2.1 FlowCon

FlowCon ist eine Erweiterung einer FlowEngine, welche die Informationen eines Kontext-Managementsystems verbessert. Es ist dadurch möglich, die Tätigkeiten des Benutzers automatisch zu erfassen und zu protokollieren. Das Ausstatten jedes Raumes mit den hierfür nötigen Sensoren ist jedoch zu teuer. Ebenso dauert die nötigen Trainingsphasen für *Body-Worn-Sensors* [Amf+06] zu lange. Deshalb werden die Aktivitäten des Benutzers mit den Sensoren eines modernen Smartphones erfasst. Neben den Aufzeichnungen des integrierten Mikrofons, werden die Werte des Beschleunigungssensors, des Kompasses und des Lagesensors ausgewertet. Zur grobgranularen Bestimmung der Position wird das vorhandene Wifi-Netzwerk mittels *Received Signal Strength Indication* (RSSI) verwendet, da das Auswerten eines GPS-Signals innerhalb eines Gebäudes nicht zuverlässig möglich ist.

Der Nachteil dieser Art der Informationserfassung ist, dass die verwendeten Sensoren und deren Daten unzuverlässig sind. Die daraus generierten Kontextinformationen weisen durch ihre deutlich höhere Abstraktionsschicht ein ebenso hohes Maß an Unsicherheit auf. Die Aktivitäten des Benutzers werden durch Kontextinformationen beschreiben. FlowCon benötigt diese in Form von Ereignissen, welche von einem *Kontext-Managementsystem* bereitgestellt werden.

Die Kontextinformationen sind allerdings zur direkten Protokollierung der Aktivitäten des Benutzers viel zu wagen. Ebenso ist es mit diesen Informationen nicht möglich einen

Workflow, der die Arbeitsabläufe des Pflegepersonals beschreibt, direkt auszuführen. Ohne eine Aufarbeitung der Kontextinformationen wäre also ein hohes Maß an Benutzerinteraktion notwendig, welche aber bewusst gering gehalten werden soll.

FlowCon greift auf die Struktur der modellierten Prozesse – welche die Arbeitsabläufe beschreiben – zurück und verbessert durch diese zusätzliche Information die Akkuratheit der Kontexterkenkung. So kann es eine stabile Ausführung der Workflows gewährleisten und mit einem geringen Maß an Benutzerinteraktion die Arbeiten des Pflegepersonals protokollieren.

Für die Modellierung der Prozesse verwendet FlowCon *Adaptable Pervasive Workflows*, kurz *Flows*, da diese speziell für die Repräsentation und interne Verarbeitung entwickelt wurden.

Die Leistungsfähigkeit von FlowCon wird anhand der vollständig aufgezeichneten *Flows* gemessen, der *Flow*-Erkennungsrate. Anhand dieser Rate bzw. Metrik werden die späteren Ergebnisse verglichen.

2.1.1 Implementierungsdetails von FlowCon

In dieser Diplomarbeit wird FlowCon erweitert und es wird geprüft, welchen Einfluss die Wahl eines geeigneten Unsicherheitsmodells hat. Für das Verständnis sind einige grundlegende Architektureigenschaften und Implementierungsdetails von FlowCon entscheidend. Daher befasst sich der folgenden Abschnitt mit diesen Details. Eine vollständige Beschreibung von FlowCon ist in [WHR10] zu finden.

Kontextverarbeitung

Wie schon erwähnt, setzt FlowCon ein Kontextmanagementsystem voraus, welches die Aktivitäten des Benutzers in Form von Ereignissen bereitstellt. Ein solches Ereignis wird intern von FlowCon als *Event-Instance* dargestellt. Diese hat einen Ereignistyp, der die infrage kommenden, möglichen, verschiedenen Aktivitäten angibt, und eine Ereignisverteilung (Event-Value). Dieser zuletzt genannte Datentyp stellt eine probabilistische Wahrscheinlichkeitsverteilung über den Möglichkeiten des Ereignistyps dar. Die *Event-Instance* kann somit als Funktion angesehen werden, die ein Ereignis auf einen Wahrscheinlichkeitswert abbildet. Die folgende Definition beschreibt diesen Zusammenhang genauer:

Definition 1 (Event-Instance):

Sei E die Menge aller möglichen Ereignisse eines Ereignistyps, dann definiert eine *Event-Instance* $I_E : E \mapsto [0, 1]$ eine probabilistische Wahrscheinlichkeitszuweisung über den Ereignistyp, sodass gilt:

$$\sum_{e \in E} I_E(e) = 1$$

Die soeben definierte mathematische Funktion einer *Event-Instance* $I_E(e)$ bildet das probabilistische Modell von FlowCon und dient zur Darstellung von Unsicherheit. Die Definition der *Event-Instance* wird im Laufe dieser Diplomarbeit, entsprechend des gewählten Unsicherheitsmodells, abgeändert.

Flow-Modell

FlowCon modelliert den Arbeitsablauf intern mithilfe eines *Flow-Modells*. Ein solches lässt sich als Quadrupel $\mathcal{F} = (A, T, C, \mu)$ darstellen. Dieser Tupel besteht in erster Linie aus den Aktivitäten $a \in A$ des *Flows* und den dazugehörigen Transitionen $t \in T$. Letztere modellieren die Übergänge von einer zur nächsten Aktivität. Transitionen lassen sich mathematisch wie folgt definieren:

Definition 2 (Transition):

Sei A die Menge aller Aktivitäten eines *Flows*, dann ist die Menge aller Transitionen definiert als $T \subseteq A \times A$. Eine Transition (a_x, a_y) entspricht somit einer gerichteten Übergangsmöglichkeit von der Aktivität a_x zur Aktivität a_y .

Solche Transitionen können mit einer Übergangsbedingung, auch als *Condition* bezeichnet, versehen sein. Nur wenn diese Bedingung erfüllt ist, kann diese Transition einen Aktivitätswechsel durchführen.

Definition 3 (Condition):

Sei E der Ereignistyp und sei C die Menge aller Übergangsbedingungen, dann ist eine Übergangsbedingung induktiv definiert als:

$$c \rightarrow I_E(e) \quad \text{mit } e \in E \quad (2.1)$$

$$c \rightarrow c_1 \vee c_2 \quad \text{mit } c_1, c_2 \in C \quad (2.2)$$

$$c \rightarrow c_1 \wedge c_2 \quad \text{mit } c_1, c_2 \in C \quad (2.3)$$

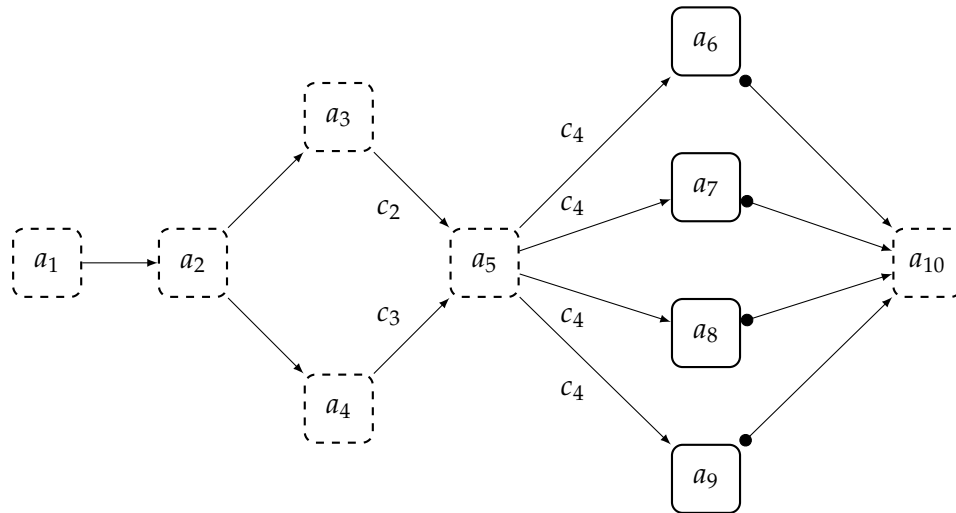
$$c \rightarrow \neg c_1 \quad \text{mit } c_1 \in C \quad (2.4)$$

FlowCon verwendet zur Auswertung der Bedingungen einen sogenannten *Condition-Evaluator*. Dieser verwendet für die Operatoren der zuvor beschriebenen Transitionsbedingungen die Konjunktion, Disjunktion und Negation der Binär-Logik. Hierzu vergleicht dieser das Ergebnis der *Event-Instance* mit dem Navigationsschwellwert t . Ist dieser überschritten, also gilt $I_E(e) \geq t$, wird die Teilbedingung auf *Wahr* gesetzt, im anderen Fall auf *Falsch*. Die restlichen Verknüpfungen und Knoten der Bedingungen entsprechen der Binär-Logik.

Der μ -Wert des *Flow-Modells* \mathcal{F} markiert, welche Transitionen notwendig und welche optional sind, um eine Aktivität zu beginnen. Ohne diese Markierung müssten, um die Aktivität zu beginnen, alle Aktivitäten der eingehenden Transitionen abgeschlossen sein.

Dies ist notwendig, da es in einem Arbeitsablauf Verzweigungen und Zusammenführungen beliebiger Art geben kann.

Zur Illustration der Zusammenhänge von Aktivitäten, Transitionen, Bedingungen und Markierungen, ist in Abbildung 2.1 ein *Flow-Modell* dargestellt.



a_1	Blutdruckmanschette anlegen	a_5	Kanüle legen	a_9	Blutprobe 4
a_2	Vene suchen	a_6	Blutprobe 1	a_{10}	Etikettieren
a_3	Kanüle auspacken	a_7	Blutprobe 2		
a_4	Ellenbeuge desinfizieren	a_8	Blutprobe 3		

Abbildung 2.1: Ein *Flow-Modell* [WHR10]

Bayes'sches Netz

Um die Korrektheit der Erkennung zu erhöhen, zeichnet FlowCon die Reihenfolge der durchgeführten Aktivitäten auf. Die gespeicherten Arbeitsabläufe dienen dazu ein Bayes'sches Netz zu trainieren. Dieses Netz erfasst somit die Gewohnheiten des Benutzers und versucht den nächsten Arbeitsschritt – aus den bisherigen Arbeitsabläufen – vorherzusagen. FlowCon zieht diese Vorhersage in der Auswertung einer *Event-Instance* mit ein. Das Bayes'sche Netz stellt somit eine weitere Informationsquelle dar. Zur genaueren Differenzierung wird diese Quelle als Q^{BN} bezeichnet. Analog dazu stellt Q^{CMS} das Kontextmanagementsystem dar. Zur Bestimmung der Wahrscheinlichkeit eines Ereignisses e vom Ereignistyp E mittelt FlowCon die Werte beider Quellen.

$$I_E(e) = \frac{Q^{CMS}(e) + Q^{BN}(e)}{2}, \quad \text{für alle } e \in E \quad (2.5)$$

Ereignisse $e \in E$ die einen großen Wert $Q^{BN}(e)$ aufweisen führen zu einem üblichen Arbeitsablauf. Durch die Mittelung aus der vorherigen Gleichung 2.5 werden Ereignisse, die zu einem gängigen Arbeitsablauf führen gestärkt, unübliche hingegen werden geschwächt.

Der daraus resultierende Aufbau und die Zusammenhänge, zwischen dem Kontext-Managementsystem (CMS) und dem Bayes'schen Netz (BN), sind in Abbildung 2.2 dargestellt.




Abbildung 2.2: Aufbau von FlowCon [WHR10]

Simulationen zeigten, dass die Korrektheit der Kontexterkenkung, und somit auch die Anzahl der vollständig erkannten Arbeitsabläufe, durch diese zusätzlichen Informationen gesteigert werden konnte [WHR10].

2.2 Abgrenzung zu anderen Systemen

2.2.1 Kontextbasierte Systeme

Schon seit langer Zeit beschäftigen sich viele Arbeiten mit der Integration von Kontextinformationen in vorhandene Systeme. Ursprünglich ging es nur um die Position des Benutzers und die automatische Adaption von Mobilgeräten [SBG99]. Bald wurde das Ziel dahingehend erweitert, dass das System sich nicht nur dem Ort, sondern auch dem persönlichen Ziel des Benutzers anpassen sollte. Ein solches Ziel ist aber eine viel abstraktere Ebene des Kontextes als nur der Ort. Es besteht zum einen aus mehreren verschiedenen Informationen, zum anderen aus mehreren einzelnen Abläufen. Für diesen Fall wurden PerFlows [Urb+09] entwickelt, mit denen man Aktivitäten als Workflow modellieren kann. Dadurch ist es einem System möglich, sich anhand des Workflows anzupassen.

Bei der Verarbeitung der Kontextinformationen zeigte sich sehr schnell ein Problem. Zwischen der Abstraktionsebene der benötigten Informationen und der Ebene, die derzeit von

Sensoren geliefert wird, klafft eine beträchtliche Lücke. Die Systeme schätzen daher den „High-Level-Kontext“ aus den vorhandenen „Low-Level-Sensorwerten“ ab. Sensoren sind zudem anfällig für Störungen und Rauschen. Diese Punkte führen zu einem hohen Maß an Unsicherheit.

In [Wie+09] wurde daher vorgeschlagen, Kontextdaten mit einer Qualitätsangabe zu versehen. Mit Hilfe von *Policies* können schlechte Kontextinformationen gefiltert werden, um eine falsche Ausführung zu verhindern. Leider wurde in diesem Artikel nicht geklärt, wie vorzugehen wäre bzw. vorgegangen werden kann, falls nur sehr unsichere Informationen zu Verfügung stehen.

Um die Robustheit der Kontexterkenkung zu erhöhen, und somit die Fehleranfälligkeit zu reduzieren, gibt es einige Ansätze.

M. Berchtold und M. Beigl [BB09] erweitern einen Kontextklassifikator – der aus den Sensorwerten den Kontext extrahiert – um eine Unsicherheitsangabe. Sein Recurrent-Fuzzy-Inference-System (RFIS) bezieht die zuvor erkannte Kontextinformation in die Bestimmung des neuen Kontexts mit ein. Es konnte darüber hinaus gezeigt werden, dass der vorgestellte RFIS-Klassifikator eine deutlich höhere und korrektere Erkennungsrate hat als ein herkömmlicher Klassifikator.

2.2.2 Erkennung von menschlichen Aktivitäten

Andere Arbeiten befassten sich mit der Vision, wie sich Räume und Orte den Benutzern anpassen.

Ein solches Projekt war Smart-Spaces [CM00]. Hier wurden sowohl feste Sensoren in einem Raum als auch mobile Sensoren eingesetzt. Aus deren Daten wird über ein Bayes'sches Netz für alle Anwendungen der Kontext in Form einer probabilistischen Wahrscheinlichkeitsverteilung bestimmt. Auch in dieser, doch sehr frühen, Arbeit spielte die Qualität der Kontextinformationen eine wichtige Rolle. Die Entropie der Verteilung schien eine gute Angabe für die Sicherheit und Güte der Kontextinformation zu sein.

Ähnlich zu den Smart-Spaces, befasst sich T. Barger, D. Brown und M. Alwan [BBA05] mit der Idee intelligente Räumlichkeiten einzusetzen. Ziel des SmartHouse-Projekts war es, älteren Menschen die Möglichkeit zu geben, solange wie möglich in ihrem eigenen und gewohnten Zuhause zu leben. Die Räumlichkeiten wurden dabei mit Sensoren ausgestattet, um eine gesundheitliche Überwachung zu ermöglichen. Zum Einsatz kamen neben Bewegungsmeldern auch einfache Schalter, die an Küchengeräten und wichtigen Orten angebracht wurden. Dies ermöglichte es Rückschlüsse auf getane Tätigkeiten und Aktivitäten zu ziehen und somit Gewohnheitsmuster zu bilden. Solche Muster sind robust gegen Störungen und eignen sich daher gut für das beschriebene Einsatzgebiet. Weicht ein Benutzer von diesen Mustern ab, kann man notwendige Schritte einleiten und Hilfe rufen.

Ein ähnliches System wurde von J. Biswas u. a. [Bis+10] vorgestellt. Es dient zum gesundheitlichen Überwachen von Demenzpatienten. Zur Bestimmung des Kontexts sind ebenfalls feste Sensoren in den Räumlichkeiten installiert. Das System von J. Biswas u. a. [Bis+10] verwendet ein Wahrscheinlichkeitsmodell um die Unsicherheit der Sensoren darzustellen. Beim Überschreiten eines Schwellwerts wird in den nächsten Zustand gewechselt. Da Übergangsmuster robust gegen Rauschen sind, wird über die Zustandswechsel der Kontext bestimmt. Ebenso wird anhand eines Zustandsautomaten bestimmt, welcher Sensor zur Bestimmung eines angefragten Werts verwendet wird. Zum Beispiel kann eine Beatmungsmaske während der Nahrungsaufnahme nicht getragen werden. Sie liefert in dieser Zeit keine verwertbaren Informationen.

2.3 Zusammenfassung

Kontextinformationen sind ein wichtiger Teil von adaptiven und intelligenten Systemen. Die Bestimmung des Kontextes ist aufgrund von fehlenden Sensoren nur über Umwege möglich. Dies bringt, wie gezeigt, einige Probleme mit sich.

Obwohl alle Arbeiten darauf eingehen, dass die Unsicherheit der Kontextinformationen eine große Rolle spielt, verwendet keines dieser Systeme ein spezielles Modell zur Darstellung der zugrundeliegenden Unsicherheit. Lediglich eines der vorherigen Systeme verwendet die probabilistische Wahrscheinlichkeitstheorie, ohne näher auf die Gründe für diese Wahl einzugehen. Dabei gibt es Unsicherheitsmodelle, die die vorhandene Unsicherheit deutlich besser darstellen können und mehr Möglichkeiten zur Auswertung bieten.

Ziel des nächsten Kapitels ist es daher, ein geeignetes Unsicherheitsmodell für FlowCon zu finden, um damit die *Flow*-Erkennungsrate zu steigern.

3 Unsicherheitsmodelle

3.1 Einleitung

Kontextinformationen werden in der Regel von einem Kontext-Managementsystem erfasst und entsprechend weiter verarbeitet. Dieses greift hierzu auf Sensordaten zurück, welche normalerweise erst auf Merkmale abgebildet werden. Diese Merkmale bilden den Merkmalsraum, auf dessen Grundlage der Klassifikator den Kontext des Systems bestimmt. Dabei bildet der Klassifikator die Merkmale auf die für das System relevanten Situationen ab. Diese Situationen bilden den Kontext. Da die verschiedenen zur Verfügung stehenden Merkmale nicht immer eindeutig sind, liegt eine Darstellung als Wahrscheinlichkeitsverteilung nahe.

Da der Kontext nicht direkt bestimmt wird, entsteht ein hohes Maß an Unsicherheit. In der Regel optimiert man den Klassifikator sowie den Merkmalsextraktor auf ein fixes Problem hin. Dies ist in dynamischen und mobilen Umgebungen nur schwer möglich. Daher spielt die Unsicherheit in solchen Umgebungen eine entscheidende Rolle.

Die klassische Wahrscheinlichkeitstheorie bietet – bei näherer Betrachtung – keine Möglichkeit Unsicherheit und Unkenntnis über gewisse Faktoren korrekt darzustellen. Wenn daher eine Zuordnung der Wahrscheinlichkeit zu einem bestimmten Merkmal nicht möglich ist, bleibt als Lösung meistens nur, diese auf alle infrage kommenden Möglichkeiten aufzuteilen. [Bar81; Jøso7]

Dies führt unter Umständen zu falschen Folgerungen beziehungsweise einer falschen Darstellung des Sachverhalts. Ein Beispiel hierfür ist das Ellsberg-Paradoxon, welches im folgenden Abschnitt in einer gekürzten Form behandelt wird.

3.1.1 Ellsberg-Paradoxon

Beim Ellsberg-Paradoxon [Ell61] gibt es 90 farbige Kugeln. 30 davon sind rot. Die restlichen 60 sind entweder schwarz oder gelb, wobei das genaue Verhältnis unklar ist. Es wird zufällig eine Kugel gezogen und je nach Farbe gewinnt man oder verliert man.

D. Ellsberg stellte zwei mögliche Wetten auf. Bei der ersten Wette gewinnt man bei einer roten Kugel 100 €. Bei der zweiten Wette gibt es das Preisgeld bei einer schwarzen Kugel. Die meisten Menschen entscheiden sich hier für die Wette I. Sie gehen also von einer höheren

Gewinnchance bei einer roten Kugel aus, als bei einer schwarzen Kugel. Diesem Verhalten nach müsste die Wahrscheinlichkeit einer roten Kugel größer sein, als die einer schwarzen Kugel [Ell61].

Wette	Rot	Schwarz	Gelb
Wette I	100 €	0 €	0 €
Wette II	0 €	100 €	0 €
Wette III	100 €	0 €	100 €
Wette IV	0 €	100 €	100 €

Tabelle 3.1: Die vier Wetten des Ellsbergs-Paradoxons

Ändert man die beiden Wetten so ab, dass man zusätzlich auch bei einer gelben Kugel gewinnt, ändert sich die Einschätzung der Testpersonen. Bei den neuen Wetten III und IV, die ebenso wie die ersten beiden Wetten in Tabelle 3.1 aufgeführt sind, entscheiden sich die meisten Testpersonen für die Wette IV. Bei dieser gewinnt man sowohl mit einer schwarzen als auch mit einer gelben Kugel. Nach diesem Verhalten müsste die rote Kugel eine geringere Wahrscheinlichkeit und Gewinnchance aufweisen als eine schwarze Kugel. Da aber am Verhältnis der Kugeln nichts geändert wurde, steht dies im Widerspruch zur vorherigen Erkenntnis, dass rote Kugeln eine höhere Chance aufweisen [Ell61].

Nach der Entscheidungstheorie müssten sich eigentlich die meisten Testpersonen für Wette III entscheiden, was sie aber nicht tun. Dieses Verhalten zeigt, dass man zwischen Risiko und Unsicherheit unterscheiden muss [Ell61].

Im Falle von FlowCon entspricht das Risiko der Evidenz, die korrekt zugeordnet werden konnte. Die Unsicherheit hingegen entspricht der erfassten Evidenz, die sich aber nicht eindeutig zuordnen ließ.

Das Ellsberg-Paradoxon wird in der weiteren Arbeit als Test verwendet, um zu prüfen ob die behandelten Unsicherheitsmodelle diese Unterscheidung zwischen Unsicherheit und Wahrscheinlichkeit ermöglichen oder ob sie für ein solches Einsatzgebiet ungeeignet sind.

3.1.2 Überblick

In den weiteren Abschnitten dieses Kapitels werden drei verschiedene Unsicherheitsmodelle vorgestellt. Dabei wird geprüft ob und in welcher Form das jeweilige Unsicherheitsmodell in das vorgestellte FlowCon integriert werden kann.

Hierfür werden im ersten Abschnitt 3.2 Anforderungen definiert, die ein Unsicherheitsmodell zur Integration in FlowCon erfüllen muss. Der darauf folgende Abschnitt 3.3 befasst sich mit der Dempster-Shafer-Theorie, welche auch als Evidenztheorie bekannt ist. Die ursprünglich

von N. D. Belnap Jr. stammende Vier-Wertige-Logik wird im anschließenden Abschnitt 3.4 behandelt. Das letzte behandelte Unsicherheitsmodell ist die Subjektive-Logik. Dabei handelt es sich um eine probabilistische Logik, welche es erlaubt Unsicherheit explizit auszudrücken. Sie wird ausführlich in Abschnitt 3.5 behandelt.

3.2 Anforderungen an ein Unsicherheitsmodell

Um die vorgestellten Unsicherheitsmodelle besser vergleichen und überprüfen zu können, werden in diesem Abschnitt Anforderungen aufgestellt. Diese Anforderungen sollten – wenn irgendwie möglich – alle erfüllt sein, damit das Modell sinnvoll in FlowCon integriert werden kann.

- A-1** *Explizite Darstellung von Unsicherheit.*
Das Unsicherheitsmodell muss eine explizite Darstellung von Unsicherheit aufweisen. Ebenso muss diese Unsicherheit bei den Berechnungsvorschriften der Operatoren mit einbezogen werden.
- A-2** *Werte und Ergebnisse müssen auswertbar sein.*
Es muss anhand der Werte und Ergebnisse des Unsicherheitsmodells entscheidbar sein, ob diese eine Transitionsbedingung erfüllen oder nicht.
- A-3** *Werte und Ergebnisse müssen vergleichbar sein.*
Die Werte und Ergebnisse des Unsicherheitsmodells müssen untereinander vergleichbar sein, damit im Zweifelsfall eine Entscheidung für das bessere Ergebnis getroffen werden kann.
- A-4** *Werte und Ergebnisse müssen interpretierbar sein.*
Aus den Werten bzw. Ergebnissen muss die Bedeutung für den Kontext bzw. für die resultierende Schlussfolgerung klar ersichtlich sein.
- A-5** *Ergebnisse müssen intuitiv sein.*
Die Ergebnisse der Operatoren müssen aus menschlicher Sicht sinnvoll sein, da bei FlowCon menschliche Aktivitäten erfasst werden.
- A-6** *Operatoren zur Auswertung der Bedingungen.*
Zumindest die in FlowCon enthaltenen Operatoren der Transitionsbedingungen (Konjunktion, Disjunktion und Negation) müssen vom Unsicherheitsmodell klar definiert sein.
- A-7** *Inferenzregeln zum Schlussfolgern.*
Regeln und Berechnungsvorschriften zum Ableiten von Schlussfolgerungen sollen vorhanden sein.

- A-8** *Integration des Bayes'schen Netzes.*
Die Verteilung des Bayes'schen Netzes und die Verteilung des Kontext-Management-systems müssen sinnvoll und mathematisch fundiert miteinander verknüpft werden können.
- A-9** *Geringe Komplexität.*
Der Berechnungsaufwand und somit die Komplexität von FlowCon darf durch das Unsicherheitsmodell nicht weiter gesteigert werden, da FlowCon auch auf einem Mobilgerät lauffähig sein soll.
- A-10** *Das Ellsberg-Paradoxon muss darstellbar sein.*
Das Unsicherheitsmodell muss die im Ellsberg-Paradoxon vorkommenden Wahrscheinlichkeiten und die dort herrschende Unsicherheit darstellen und verwenden können.
- A-11** *Keine Einschränkung bei der Wahl des zu verwendenden Kontext-Managementsystems.*
Durch die Einführung des Unsicherheitsmodells dürfen keine weiteren Anforderungen an ein Kontext-Managementsystem entstehen. Wenn möglich sollen alle ereignisbasierten Kontext-Managementsysteme verwendet werden können.

3.3 Dempster-Shafer-Theorie

Die Dempster-Shafer-Theorie, auch bekannt als Evidenztheorie¹, ist eine mathematische Theorie zur Darstellung von Unsicherheit über gewisse Fakten. Die Unsicherheit fasst dabei die Unwissenheit bzw. die Ignoranz bezüglich eines gewissen Standpunktes oder Gesichtspunktes zusammen.

Die Grundlagen entwickelte Arthur Pentland Dempster in den 1960er Jahren [Bar81; Lv91]. Anschließend wurde diese von Depsters Student Gleen Shafer in den 1970ern erweitert und trägt seither den Namen ihrer beiden Entwickler. Sie war ursprünglich nicht zum Schlussfolgern mit Unsicherheiten in Experten-Systemen gedacht. Dieses Einsatzgebiet kam erst in den 1980ern hinzu. Neben der Eigenschaft, dass sie einen exponentiellen Berechnungsaufwand mit sich bringt, fehlen ihr hierzu auch grundlegende Funktionen und Operatoren.

Grundlagen

Die Dempster-Shafer-Theorie kann als Verallgemeinerung der Wahrscheinlichkeitstheorie angesehen werden. Sie definiert einen Betrachtungsrahmen Θ , der im Englischen „frame of discernment“ genannt wird. Dieser ist eine Menge aller, sich gegenseitig ausschließenden,

¹engl.: theory of evidence

möglichen Schlussfolgerungen einer Domäne. Der Betrachtungsrahmen Θ entspricht in etwa der Grundmenge einer klassischen Wahrscheinlichkeitsverteilung der Bayes'schen Logik [Bar81]. Allerdings wird, im Gegensatz zur probabilistischen Logik, nicht jeder Möglichkeit ein einzelner Wahrscheinlichkeitswert zugewiesen, sondern zwei. Diese zwei Werte entsprechen dem minimalen Glauben² in eine Schlussfolgerung sowie deren maximaler Plausibilität³. Sie bilden somit ein Wahrscheinlichkeitsintervall bzw. ein Glaubensintervall [Lv91].

Zur Bestimmung dieser beiden Werte wird die Menge 2^Θ als Potenzmenge des Betrachtungsrahmens Θ definiert. Sie enthält neben allen Teilmengen von Θ die leere Menge und Θ selbst. Dadurch kann jeder infrage kommenden Kombination von Schlussfolgerungen ein Wahrheitswert zugewiesen werden. Eine solche Glaubenszuweisung wird *Basic Probability Assignment* (BPA) bzw. *Basic Belief Assignment*⁴ (BBA) genannt und ist eine grundlegende Eigenschaft der Dempster-Shafer-Theorie. Die folgende Definition 4 beschreibt diese Eigenschaft genauer. Sie ist, ebenso wie die restlichen Definitionen dieses Abschnitts, sinngemäß aus [Lv91] und [Bar81] entnommen.

Definition 4 (Basic Belief Assignment):

Sei Θ der Betrachtungsrahmen, dann wird eine Funktion $m_\Theta : 2^\Theta \mapsto [0, 1]$ Glaubenszuweisung genannt wenn gilt:

$$m_\Theta(\emptyset) = 0 \text{ und } \sum_{X \in 2^\Theta} m_\Theta(X) = 1.$$

Eine Wertzuweisung an einen einelementigen Eintrag von 2^Θ bedeutet, dass diese Schlussfolgerung mindestens zum angegebenen Grad wahr ist. Zuweisungen an einen nicht atomaren Eintrag von 2^Θ bedeuten hingegen, dass diese Wahrscheinlichkeit einer der enthaltenen Schlussfolgerungen zuzuordnen ist, dass allerdings keine Klarheit darüber herrscht, welcher.

Ein anschauliches Beispiel hierfür ist ein Pferderennen. Der Betrachtungsrahmen sind die Pferde, die am Start stehen. Eine Zuweisung an eine zweielementige Menge des Betrachtungsrahmens bedeutet nicht, dass man davon ausgeht, dass die beiden – durch die Menge bestimmten – Pferde zeitgleich im Ziel ankommen. Sie bedeutet vielmehr, dass eines dieser beiden Pferde mindestens zur angegebenen Wahrscheinlichkeit als Erstes im Ziel ist.

Unter Zuhilfenahme der Definition 4 lässt sich direkt die Glaubensfunktion, im Englischen „belief function“, aufstellen. Mit dieser lässt sich für eine bestimmte Kombination an möglichen Schlussfolgerungen der zugehörige Glaubenswert bestimmen.

²engl.: belief

³engl.: plausibility

⁴Diese Bezeichnung ist in der neueren Literatur üblicher, da sie die Bedeutung der Zuweisung besser beschreibt.

Definition 5 (Belief Function):

Sei m_Θ ein *Basic Probability Assignment* auf dem Betrachtungsrahmen Θ , dann ist die Glaubensfunktion $Bel : 2^\Theta \mapsto [0, 1]$ definiert als:

$$Bel(X) = \sum_{Y \subseteq X} m_\Theta(Y) \text{ und } X, Y \in 2^\Theta.$$

Die Glaubensfunktion hat einige, leicht zu prüfende, Eigenschaften [Lv91]:

1. $Bel(\Theta) = 1$.
2. Für jedes $x \in \Theta$ gilt $Bel(\{x\}) = m_\Theta(\{x\})$.
3. Für jedes $X \subseteq \Theta$ gilt $Bel(X) + Bel(\bar{X}) \leq 1$ mit $\bar{X} = \Theta \setminus X$.

Neben diesen Eigenschaften kann man zeigen, dass es zu jeder Glaubensfunktion nur eine einzige Glaubenszuweisung gibt [Bar81]. Die Gleichung aus Definition 5 ist daher bijektiv und weist jeder Menge von Schlussfolgerungen einen Wert zwischen null und eins zu. Dieser stellt die untere Grenze des Glaubensintervalls dar. Der Plausibilitätswert hingegen entspricht der oberen Grenze dieses Intervalls. Er wird, für eine gegebene Kombination von Schlussfolgerungen, über die Plausibilitätsfunktion, im Englischen *Plausibility Function* genannt, bestimmt.

Definition 6 (Plausibility Function):

Sei m_Θ ein *Basic Probability Assignment* auf dem Betrachtungsrahmen Θ , dann ist die *Plausibility Function* $Pl : 2^\Theta \mapsto [0, 1]$ definiert als:

$$Pl(x) = \sum_{x \cap y \neq \emptyset} m_\Theta(y) \text{ für alle } y \subseteq \Theta.$$

Alternativ zur Definition 6 kann die Plausibilitätsfunktion $Pl(X)$ auch wie folgt definiert werden:

$$Pl(X) = 1 - Bel(\bar{X}) \text{ mit } \bar{X} = \Theta \setminus X. \tag{3.1}$$

Abbildung 3.1 zeigt ein Glaubensintervall mit den eingezeichneten Werten $Bel(x)$ und $Pl(x)$.




Abbildung 3.1: Glaubensintervall

Die Unsicherheit für eine bestimmte Schlussfolgerung bzw. einer Menge von Schlussfolgerungen entspricht $Pl(X) - Bel(X)$ [GS84]. Ist diese für alle Teilmengen X des Betrachtungsrahmens Θ gleich null, haben wir eine Verteilung, die der klassischen Wahrscheinlichkeitstheorie entspricht. Dies zeigt, dass man die Dempster-Shafer-Theorie – wie schon erwähnt – als Erweiterung bzw. Verallgemeinerung der Bayes'schen Wahrscheinlichkeitstheorie ansehen kann [Lv91]. Es herrscht allerdings Unstimmigkeit darüber, ob ein Glaubensintervall den Bereich der tatsächlichen Wahrscheinlichkeit einschränkt [Lv91; Sha92], bzw. was die Breite eines Intervalls bedeutet [RNo4, S. 645].

3.3.1 Dempster'sche Kombinationsregel

Zum Kombinieren von Evidenz aus verschiedenen Quellen gibt die Dempster-Shafer-Theorie eine Kombinationsregel an, bekannt als „Dempster's rule of combination“. Mit ihr werden zwei verschiedene Einschätzungen desselben Sachverhalts zu einer gemeinsamen Einschätzung verbunden. Sie verbindet somit zwei Glaubenszuweisungen zu einer neuen Glaubenszuweisung.

Definition 7 (Dempster's rule of combination):

Seien m_1 und m_2 zwei Basic Probability Assignments auf dem Betrachtungsrahmen Θ . Dann ist die $m_1 \oplus m_2$ eine Funktion $m_1 \oplus m_2 : 2^\Theta \mapsto [0, 1]$ sodass gilt:

$$m_1 \oplus m_2(X) = \begin{cases} 0 & \text{für } X = \emptyset \\ \frac{\sum_{Y \cap Z = X} m_1(Y) \cdot m_2(Z)}{\sum_{Y \cap Z \neq \emptyset} m_1(Y) \cdot m_2(Z)} & \text{für alle } X \neq \emptyset \end{cases}$$

Die folgenden Beispielrechnungen sollen die Verwendungsmöglichkeit und Eigenschaften der obigen Regel veranschaulichen.

Beispiel 1:

Am Start eines Pferderennens stehen die Pferde A , B und C . Zwei verschiedene Beobachter geben ihre Prognose (Hypothese) für das erste Pferd im Ziel an. Der Betrachtungsrahmen ist daher als $\Theta = \{A, B, C\}$ definiert. Die Hypothesen der Beobachter sind als Glaubenszuweisungen m_1 und m_2 gegeben:

$$m_1(X) = \begin{cases} 0.6 & \text{für } X = \Theta \\ 0.4 & \text{für } X = \{A, C\} \\ 0.0 & \text{sonst} \end{cases} \quad (3.2)$$

$$m_2(X) = \begin{cases} 0.5 & \text{für } X = \Theta \\ 0.5 & \text{für } X = \{B\} \\ 0.0 & \text{sonst} \end{cases} \quad (3.3)$$

Die Bestimmung der einzelnen Werte kann als Schnittmengentabelle, auch „*intersection tableau*“ genannt, dargestellt werden [Lv91]. Es handelt sich dabei um eine Tabelle, die die einzelnen Ergebnisse der Schnittmengen von m_1 und m_2 enthält. Eine solche ist für das obige Beispiel in Tabelle 3.2 zu sehen.

	$m_1(\{A, C\}) = 0.4$	$m_1(\Theta) = 0.6$
$m_2(\{B\}) = 0.5$	$\emptyset : 0.0 (0.2)$	$\{B\} : 0.375 (0.3)$
$m_2(\Theta) = 0.5$	$\{A, C\} : 0.25 (0.2)$	$\{\Theta\} : 0.375 (0.3)$

Tabelle 3.2: Schnittmengentabelle für m_1 und m_2 . In den Klammern befinden sich die jeweils unskalierten Werte.

Rechnerisch wird der leeren Menge \emptyset ein Wert größer null zugewiesen. Die Definition 7 auf der vorherigen Seite setzt den Wert für die leere Menge \emptyset aber explizit auf null und skaliert die restlichen Werte entsprechend, sodass die Summe wieder eins ergibt. Das Resultat ist somit wieder eine korrekte Glaubenszuweisung.

3.3.2 Berechnungsaufwand und unintuitive Ergebnisse

Anhand der möglichen Größe der Tabellen und der Anzahl der einzelnen Ergebnisse ist der Rechenaufwand, den die Dempster-Shafer-Theorie mit sich bringt, abschätzbar. Die Glaubenszuweisungen m_1 und m_2 aus Beispiel 1 enthalten jeweils nur zwei – von null verschiedene – Einträge. Prinzipiell ist es aber möglich, dass diese $|2^\Theta|$ viele Einträge besitzen. Die Tabelle würde somit auf $|2^\Theta|^2$ verschiedene Felder anwachsen. Der exponentielle Rechenaufwand der Dempster-Shafer-Theorie ist hier deutlich zu erkennen. Speziell für große Betrachtungsrahmen führt dies automatisch zu Berechnungsproblemen.

Die Dempster’sche Kombinationsregel enthält aber noch weitere Tücken, wie L. A. Zadeh [Zad86] feststellte. Ihre Ergebnisse sind nicht immer intuitiv und weichen, in manchen Fällen, stark von der menschlichen Erwartung ab. Zur Veranschaulichung wird das Beispiel des Pferderennens (Bsp. 1 auf der vorherigen Seite) leicht abgeändert.

Beispiel 2:

Zwei Beobachter geben wieder ihre Einschätzung für das Siegerpferd ab. Da das Pferd C im vorherigen Rennen gestürzt ist, gehen beide Beobachter davon aus, dass dieses nicht gewinnen wird. Der erste Beobachter prognostiziert daher den Sieg von Pferd A, der Andere hingegen den von Pferd B. Die Glaubenszuweisungen sehen somit wie folgt aus:

$$m_3(X) = \begin{cases} 0.99 & \text{für } X = \{B\} \\ 0.01 & \text{für } X = \{C\} \\ 0.0 & \text{sonst} \end{cases} \quad (3.4)$$

$$m_4(X) = \begin{cases} 0.99 & \text{für } X = \{A\} \\ 0.01 & \text{für } X = \{C\} \\ 0.0 & \text{sonst} \end{cases} \quad (3.5)$$

Erwartungsgemäß müsste in der Kombination der beiden Einschätzungen das Pferd C eine sehr geringe Wahrscheinlichkeit aufweisen, da beide Beobachter diese Möglichkeit nahezu komplett ausschließen. Das Ergebnis von $m_3 \oplus m_4$, zu sehen in Tabelle 3.3, zeigt aber ein völlig anderes Ergebnis. Das Pferd C ist hier der klare Favorit und bekommt eine Wahrscheinlichkeit von 100%.

	$m_3(\{B\}) = 0.99$	$m_3(\{C\}) = 0.01$
$m_4(\{A\}) = 0.99$	$\emptyset : 0.0 (0.9801)$	$\emptyset : 0.0 (0.0099)$
$m_4(\{C\}) = 0.01$	$\emptyset : 0.0 (0.0099)$	$\{S\} : 1.0(0.0001)$

Tabelle 3.3: Schnittmengentabelle für m_3 und m_4 . In den Klammern befinden sich die jeweils unskalierten Werte.

Das Problem im vorherigen Beispiel 2 liegt laut J. A. Barnett [Bar81; Bar91]; K. Sentz und S. Ferson [SF02]; L. A. Zadeh [Zad86] im hohen Konfliktgrad der beiden Glaubenszuweisungen m_3 und m_4 . Dieser wirkt sich durch die starke Normierung und das Wegfallen von Faktoren so aus, dass eine eher unwahrscheinliche Schlussfolgerung stark erhöht wird.

Der Konfliktgrad entspricht dem Normierungsfaktor aus Definition 7 auf Seite 25 und wird in Definition 8 noch einmal genauer beschrieben. Nähere Details sind in J. Dezert und A. Tchamova [DT11] zu finden.

Definition 8 (degree of conflict):

Seien m_1 und m_2 Glaubenszuweisungen auf dem Betrachtungsrahmen Θ . Der Konfliktgrad ist dann definiert als:

$$K_{12} \triangleq \sum_{Y \cap Z = \emptyset} m_1(Y) \cdot m_2(Z) \text{ mit } Y, Z \subseteq \Theta$$

Viele Autoren versuchten, aufgrund der unintuitiven Ergebnisse, die Dempster'sche Kombinationsregel anzupassen. Andere wiederum definieren, dass diese nur auf Situationen mit geringem Konfliktgrad angewendet werden darf. Nähere Informationen hierzu sind in

M. Daniel [Dano3]; S. Destercke und D. Dubois [DD11]; J. Dezert [Dez02]; A. Jøsang und S. Pope [JP10]; F. Pichon und T. Denoeux [PD10] zu finden.

R. Haenni [Hae05]) sieht hingegen das Problem in der Definition der zwei Glaubenszuweisungen, da diese sich implizit gegenseitig ausschließen und keine Unsicherheiten aufweisen. Somit bleibt als einzige Möglichkeit nur noch die unintuitive Schlussfolgerung. Als Lösungsansatz wurden daher Regeln aufgestellt, die definieren, welche Charakteristiken eine Glaubensfunktionen und ihre Glaubenszuweisung aufweisen müssen, damit man die Dempster'sche Kombinationsregel anwenden darf.

Es können aber auch in Situationen mit geringem Konfliktgrad unintuitive Resultate auftreten [DT11]. Dies ist bedingt dadurch, dass die Dempster'sche Kombinationsregel keine Mittelung oder kumulative Verknüpfung zweier Glaubensfunktionen darstellt. Sie entspricht stattdessen einer seriellen Kombination statistischer Bedingungen und wird daher falsch angewandt und interpretiert. Nach A. Jøsang und S. Pope [JP10] entsteht dieses Missverständnis dadurch, dass sich die Dempster'sche Kombinationsregel bei einem geringen Konfliktgrad verhält wie eine Näherung für die beiden genannten Verknüpfungen (Kumulation und Mittelung).

3.3.3 Verwendungsmöglichkeiten in FlowCon

Mit der Dempster-Shafer-Theorie ist es möglich, Unsicherheit sehr genau und auf verschiedenen Ebenen darzustellen. Das Kugel-Szenario des Ellsberg-Paradoxons lässt sich mit der untenstehenden Glaubenszuweisung aus Gleichung 3.6 darstellen.

$$m_{\Theta}(X) = \begin{cases} 0.3\bar{3} & \text{für } X = \{R\} \\ 0.6\bar{6} & \text{für } X = \{S, G\} \\ 0 & \text{sonst} \end{cases} \quad (3.6)$$

Mit dieser Glaubenszuweisung kann für jede mögliche Schlussfolgerung ein Glaubensintervall bestimmt werden.

Die in Tabelle 3.1 auf Seite 20 enthaltene Wette I des Ellsberg-Paradoxons weist einen höheren Glaubenswert auf als die – ebenfalls in dort aufgeführte – Wette II. Der Plausibilitätswert hingegen ist deutlich geringer. Testpersonen entscheiden sich daher meistens für die Wette, die einen höheren Glaubenswert aufweist. Sie gehen implizit davon aus, dass die Unsicherheit gegen sie arbeitet und die Verteilung der schwarzen und gelben Kugeln immer zu ihren Ungunsten ausfällt. Die Dempster-Shafer-Theorie erfüllt damit die Anforderung A-10 (Ellsberg-Paradoxons).

Diese Eigenschaft macht sie, als Grundlage zum Schlussfolgern in KI-basierten Systemen wie FlowCon, sehr interessant. So wäre es denkbar, dass ein Kontext-Managementsystem sehr präzise angibt, was es erkannt hat und was nicht, bzw. zwischen welchen Schlussfolgerungen

Unsicherheit besteht. Allerdings ist es eher unüblich, dass ein Kontext-Managementsystem eine Glaubenszuweisung oder Glaubensfunktion als Verteilung liefert. Trotzdem sind die Anforderungen A-1 (Darstellung) und A-11 (Kontext-Managementsystem) erfüllt, da fast alle Angaben der verschiedenen Kontext-Managementsysteme in eine Glaubenszuweisung überführt werden können.

Für die Auswertung der Transitionsbedingungen fehlen der ursprünglichen Version der Dempster-Shafer-Theorie die nötigen Operatoren [Lv91]. Diese sind aber in anderen Arbeiten als Erweiterung zu finden. Da die ursprüngliche Fassung diese Operatoren (A-6) jedoch nicht aufweisen kann, werden die Anforderungen A-6 und A-7 (Inferenz) nur als teilweise erfüllt betrachtet.

Sowohl das Kontext-Managementsystem als auch das Bayes'sche Netz stellen – wie in Kapitel 2.1 – eine Informationsquelle dar. Solche werden in der Dempster-Shafer-Theorie mit der Dempster'schen Kombinationsregel verbunden. Allerdings liefert das Bayes'sche Netz bzw. dessen zugehörige Quelle Q^{BN} nur eine einfache Wahrscheinlichkeitsverteilung, bei der die Dempster'sche Kombinationsregel, aufgrund der fehlenden Unsicherheit, unintuitive Ergebnisse liefern kann.

Der Ansatz, das Bayes'sche Netz zu erweitern, sodass dieses ebenfalls eine Glaubenszuweisung zurückliefert, scheitert an der Komplexitätsanforderung (Anforderung A-9). Der Grund ist, dass eine Glaubenszuweisung die Berechnung von einer exponentiell höheren Anzahl von Werten erfordert, als eine normale Verteilung. Dies erhöht den Rechenaufwand immens, da dieser ebenfalls exponentiell mit der Knotenanzahl wächst. Somit ist dies keine Lösung für das Kombinationsproblem. Die Anforderungen A-5 (intuitive Ergebnisse) und A-8 (Bayes'sches Netz) sind folglich nicht erfüllt, was gegen eine Verwendung der Dempster-Shafer-Theorie spricht.

Ein weiterer offener Punkt ist die Tatsache, dass es nicht geklärt ist, wie man die Glaubensintervalle vergleicht oder auswertet [Sha92]. Wie geht man mit einer Schlussfolgerung um, bei der wenig dafür, aber gar nichts dagegen spricht. Ist diese nun besser oder schlechter als eine andere Schlussfolgerung, bei der viel dafür, allerdings auch vieles dagegen spricht?

Allgemein sind die Glaubensintervalle nur bedingt vergleichbar und auswertbar, weshalb die dies bezügliche Anforderung A-3 nicht erfüllt ist. Die Anforderung A-2 an die Auswertbarkeit kann als teilweise erfüllt betrachten werden, da die Intervalle zumindest anhand ihres Glaubenswertes und ihrer Breite differenziert werden können.

Die aufgeführten Nachteile schränken die Verwendungsmöglichkeiten der Dempster-Shafer-Theorie, als Erweiterung von FlowCon, stark ein. Durch ihre Eigenschaft, Unsicherheit genau darstellen zu können, ist sie hochinteressant als Eingabe für FlowCon. Zur Weiterverarbeitung ist sie, da sie die Anforderungen nicht erfüllt, ungeeignet. Sie wird in dieser Ausarbeitung nur noch als Eingabe in Betracht gezogen.

3.4 Vier-Wertige-Logik

Die Vier-Wertige-Logik wurde ursprünglich von N. D. Belnap Jr. [Bel77] vorgestellt. Sie stellt nach M. C. Fitting [Fit91] eine Verallgemeinerung der Binär-Logik dar, ähnlich der Drei-Wertigen-Logik \mathcal{K}_3 von Kleene.

Die Grundidee der Vier-Wertigen-Logik ist, dass ein Computer Fragen beantwortet. Dazu greift dieser auf eine Wissensdatenbank zurück, die eine Sammlung von Informationen enthält. Solche Wissensdatenbanken weisen die Charakteristika auf, unvollständig zu sein und widersprüchliche Informationen zu enthalten. Nach der Ansicht von N. D. Belnap Jr. [Bel77] kann es daher, neben den Antworten „Ja“ und „Nein“, zwei weitere sinnvolle Antworten geben. Die klassische Binär-Logik ist, mit ihren zwei Werten t und f , aber nicht in der Lage dies darzustellen. Daher führte N. D. Belnap Jr. zwei weitere Werte ein. Sie dienen zur Darstellung von Unwissenheit⁵ \perp und zur Darstellung von widersprüchlichen Informationen⁶ \top . Gemäß seiner Idee soll der Computer diese Werte, analog der Tabelle 3.4, verwenden [Bel77; Web98].

Wert	Symbol	Tupel	Verwendung
Wahr	t	(1,0)	Alle Informationen sprechen dafür.
Falsch	f	(0,1)	Alle Informationen sprechen dagegen.
Unwissenheit	\perp	(0,0)	Es gibt keine Informationen.
Widerspruch	\top	(1,1)	Es gibt Informationen dafür und dagegen.

Tabelle 3.4: Werte der Vier-Wertigen-Logik [Bel77]

M. L. Ginsberg [Gin88; Gingo] verallgemeinerte die Vier-Wertige-Logik und führte den Begriff der *Bilattices* ein. Ein *Bilattice* ist eine Menge, auf der zwei Halbordnungen definiert sind. Mit diesen Ordnungen können die Werte anhand ihres Wahrheitsgehalts und ihres Wissensgehalts verglichen werden. Die Vier-Wertige-Logik stellt das einfachste, nicht triviale *Bilattice* dar und ist in Abbildung 3.2 auf der nächsten Seite zu sehen.

Die vertikale k -Achse entspricht der Wissensordnung⁷ \leq_k , die horizontale t -Achse der Wahrheitsordnung⁸ \leq_t . Es ist in Abbildung 3.2 zu erkennen, dass der Wert t mehr Wahrheitsgehalt besitzt als der Wert f und somit $f \leq_t t$ gilt. Bezüglich der Wissensordnung \leq_k sind diese beiden Werte t und f jedoch nicht vergleichbar. Dies liegt an dem Richtungswechsel bezüglich der k -Achse, auf dem Pfad von f nach t . Hinzukommt die Tatsache, dass die Anordnung der Werte nicht der hier dargestellten Symmetrie entsprechen muss. Natürlich gilt dasselbe für die Werte \top und \perp bezüglich der Wahrheitsachse [Fit91].

⁵In [Bel77] als *None* n bezeichnet

⁶In [Bel77] als *Both* b bezeichnet

⁷engl.: knowledge

⁸engl.: truth




Abbildung 3.2: Vier-Wertige-Logik

3.4.1 Operatoren

N. D. Belnap Jr. [Bel77] definierte neben diesen vier Werten und deren Bedeutung auch die Operatoren für Konjunktion \wedge und Disjunktion \vee sowie eine Abbildung zur Bestimmung des Komplements \sim .

Tabelle 3.5 zeigt die Wahrheitstabellen der wichtigsten Operatoren der Vier-Wertigen-Logik.

a	$\neg a$	$\sim a$
t	f	f
f	t	t
\top	\top	\perp
\perp	\perp	\top

\vee	t	f	\top	\perp
t	t	t	t	t
f	t	f	\top	\perp
\top	t	\top	\top	t
\perp	t	\perp	t	\perp

\wedge	t	f	\top	\perp
t	t	f	\top	\perp
f	f	f	f	f
\top	\top	f	\top	f
\perp	\perp	f	f	\perp

Tabelle 3.5: Operatoren der Vier-Wertigen-Logik [Tsoo2]

Das Komplement negiert sowohl den Wahrheitsgehalt als auch den Wissensgehalt. In einem *Bilattice* erzeugt die Verneinung einer Aussage kein Wissen, daher sollten die Werte \top und \perp unverändert bleiben. Dies ist beim Komplement der Vier-Wertigen-Logik nicht der Fall. Im Sinne eines *Bilattice* ist das Komplement somit keine Negation \neg . Deshalb wurde die Vier-Wertige-Logik um eine solche Negation \neg erweitert [Bel77; Gin90].

Wie in Tabelle 3.4 zu sehen ist, ist es möglich die Werte der Vier-Wertigen-Logik auch als „Pro-Contra-Tupel“ darzustellen. Anhand dieser Tupel lassen sich Gleichungen zur Berechnung der aufgeführten Operatoren aufstellen [KIo8].

$$\neg(x_1, y_1) = (y_1, x_1) \quad (3.7)$$

$$(x_1, y_1) \vee (x_2, y_2) = (x_1 \vee x_2, y_1 \wedge y_2) \quad (3.8)$$

$$(x_1, y_1) \wedge (x_2, y_2) = (x_1 \wedge x_2, y_1 \vee y_2) \quad (3.9)$$

Durch diese Gleichungen wird deutlich, dass die De-Morgan'sche Regel auch bei der Vier-Wertigen-Logik gilt. Allerdings ist $A \vee \neg A$ keine Tautologie in der Vier-Wertigen-Logik. Allgemein gibt es in der Vier-Wertigen-Logik keine Tautologien [KIo8].

Ebenso fehlt eine starke Implikation, die benötigt wird, um Wissen bzw. Regeln aus der Wissensdatenbank abzuleiten. Die Implikation von N. D. Belnap Jr. [Bel77] ist als $A \Rightarrow B \equiv \sim A \vee B$ definiert und entspricht nur einer materiellen Implikation. Sie ist also nur eine hinreichende Bedingung. Es muss aber kein inhaltlicher oder sonstiger Zusammenhang zwischen A und B herrschen. Somit ist es nicht möglich der Wissensdatenbank neue Regeln und Schlussfolgerungen hinzuzufügen. Es wurden daher verschiedene Ansätze [Gin88; KIo8; Tsoo2] vorgeschlagen, wie man die Vier-Wertige-Logik um eine starke Inferenzregel erweitern kann. Allerdings weisen alle schwächen auf und sind daher nicht als echte starke Inferenzregel geeignet.

3.4.2 Verwendungsmöglichkeiten in FlowCon

Die Vier-Wertige-Logik erfüllt dank der Werte \top und \perp die Anforderung A-1 an die Darstellung der Unsicherheit. Ebenso sind diese Werte auswertbar (A-2) und, wie die Anforderung A-4 fordert, interpretierbar.

Durch die *Bilattices* und die damit verbundenen beiden Halbordnungen, sind die Werte bezüglich ihres Wahrheits- und Wissensgehalts vergleichbar, womit die Anforderung A-3 ebenfalls erfüllt ist.

Die für FlowCon nötigen Operatoren (A-6) sind vorhanden und ihre Ergebnisse sind intuitiv und nachvollziehbar, weshalb Anforderung A-5 ebenfalls erfüllt ist. Leider fehlt eine Inferenzregel, um sinnvolle Schlussfolgerungen ziehen zu können, wodurch Anforderung A-7 als nicht erfüllt betrachtet werden muss.

Die Komplexität der Operatoren entspricht in etwa der der Binär-Logik, weshalb keine deutliche Steigerung der Laufzeit (A-9) bei der Verwendung der Vier-Wertigen-Logik zu erwarten ist.

Mit der Vier-Wertigen-Logik kann jedoch nicht die Unsicherheiten und Wahrscheinlichkeiten des Ellsberg-Paradoxons dargestellt oder beschrieben werden. Anforderung A-10 ist daher nicht erfüllt.

Ein viel wichtigerer Punkt ist, dass FlowCon primär mit mehrwertigen Wahrscheinlichkeitsverteilungen arbeitet, die mit den Verteilungen des Bayes'schen Netzes verknüpft werden. Der Informationsverlust durch die Abbildung zweier Wahrscheinlichkeitsverteilungen auf die vier Werte, der Vier-Wertigen-Logik, wäre viel zu groß. Daher ist die Vier-Wertige-Logik für die Repräsentation der Ereignisse des Kontext-Managementsystems ungeeignet. Die Anforderungen A-8 (Bayes'sches Netz) und A-11 (Kontext-Managementsystem) sind somit nicht erfüllt.

Es muss berücksichtigt werden, dass die Vier-Wertigen-Logik nicht für die Aufarbeitung oder Darstellung von Informationen gedacht ist. Ihr eigentliches Einsatzgebiet ist es, Anfragen zu beantworten, z. B. ob schon mal jemand mit einer schwarzen Kugel beim Ellsberg-Paradoxon gewonnen hat. FlowCon verwendet zur Auswertung der Transitionsbedingung die Binär-Logik und stellt für diesen Zweck eine Anfrage an eine *Event-Instance* bezüglich einer gegebenen Situation und Bedingung. Wenn es gelingt, auf Grundlage einer bzw. zweier Wahrscheinlichkeitsverteilungen, Unwissenheit und Widerspruch einer Anfrage zu bestimmen, kann diese Auswertung um die Vier-Wertige-Logik erweitert werden. Dabei ist zu berücksichtigen, wie mit Transitionsbedingungen die als Ergebnis einer Auswertung \top bzw. \perp erhalten haben, verfahren werden soll.

Aufgrund der Anforderung bezüglich des Bayes'schen Netzes (A-8) und der Anforderung bezüglich des Kontext-Managementsystems (A-11) ist die Vier-Wertige-Logik als alleinige Erweiterung von keinem großen Nutzen. Sie wurde in dieser Arbeit nur noch als Logik für die Auswertung der Transitionsbedingungen verwendet und nicht mehr für die direkte Verarbeitung des Bayes'schen Netzes.

3.5 Subjektive-Logik

Die Subjektive-Logik wurde von A. Jøsang entwickelt und ist eine Erweiterung der probabilistischen Wahrscheinlichkeitstheorie, welche die Möglichkeit bietet, Unsicherheit explizit darzustellen.

Die Wahrscheinlichkeitstheorie geht, ebenso wie die Binär-Logik, von einer idealisierten Welt aus. Beide sind daher, wie das Ellsberg-Paradoxon gezeigt hat, zur Darstellung und Beschreibung von Situationen bzw. Schlussfolgerungen der realen Welt ungeeignet. Solche Schlussfolgerungen sind meist vom Betrachter und dessen Vorwissen abhängig. Sie sind somit überwiegend subjektiv. Hinzukommt, dass menschliche Schlussfolgerungen, laut A. Jøsang, keine absolute Sicherheit aufweisen können:

However, a fundamental aspect of the human condition is that nobody can ever determine with absolute certainty whether a proposition about the world is true or false. (A. Jøsang [Jøs10])

Die Subjektive-Logik bezieht die soeben genannten Aspekte mit ein und ermöglicht es, die vorhandene Unsicherheit des Betrachters sowie dessen Vorwissen explizit anzugeben und auszuwerten. Hierzu führt die Subjektive-Logik sogenannte *Opinions* ein. Nach A. Jøsang [Jøs07] soll es dadurch möglich sein Sachverhalte der realen Welt besser zu modellieren.

3.5.1 Grundlagen

Der grundlegende Unterschied zwischen der Subjektiven-Logik und der probabilistischen Logik ist, dass die Subjektive-Logik eine Verteilung des Glaubens in die einzelnen Schlussfolgerungen beschreibt und nicht deren Wahrscheinlichkeiten. Diese Werte stellen somit, wie in der Dempster-Shafer-Theorie, den Glauben eines Betrachters auf die einzelnen Schlussfolgerungen dar und nicht die tatsächliche Wahrscheinlichkeit.

Die Summe aller Glaubenswerte innerhalb einer Verteilung muss nicht – wie bei der Wahrscheinlichkeitstheorie – eins ergeben. Der fehlende Glauben, damit die Verteilung wieder summiert eins ergibt, beschreibt die Unsicherheit des Betrachters. Bei diesem Betrachter kann es sich um ein menschliches Individuum oder ein technisches System handeln, dessen Meinung bzw. Schlussfolgerung dargestellt wird. Die ausgewiesene Unsicherheit fasst wie bei der Dempster-Shafer-Theorie die Unwissenheit des Betrachters und dessen Ignoranz über die Richtigkeit der vorliegenden Behauptungen bzw. der erfassten Evidenz zusammen. Es ist dadurch mit der Subjektiven-Logik möglich anzugeben, dass der Betrachter keine Ahnung über den vorliegenden Sachverhalt hat.

Dies ist mit der probabilistischen Wahrscheinlichkeitstheorie nicht möglich. Diese verlangt, wegen ihrer Normierung, in einem solchen Fall eine explizite Wertezuweisung, beispielsweise $p(x) = 0,5$. Eine Zuweisung von $p(x) = 0,5$ bedeutet aber ebenfalls, dass die Wahrscheinlichkeit $p(\bar{x}) = 0,5$ ist. Dies stellt eine völlig andere Aussage dar als: „Ich habe keine Ahnung“ [Jøs10].

Die Subjektive-Logik basiert auf sogenannten *Opinions*. Es gibt, nach A. Jøsang [Jøs11], drei verschiedene Klassen von *Opinions*. Diese bilden jeweils eine Art Verallgemeinerung der Binär-Logik, der probabilistischen Logik oder der Dempster-Shafer-Theorie und sind in Tabelle 3.6 aufgeführt.

Eine solche *Opinion* ist eine Angabe, wie viel für eine Schlussfolgerung spricht (Glaube⁹) und wie viel dagegen (Zweifel¹⁰). Bei einer zweiwertigen *Opinion*, die als *Binomial-Opinion*

⁹engl.: belief

¹⁰engl.: disbelief

bezeichnet wird, entspricht dies den aus der Dempster-Shafer-Theorie bekannten Grenzen $Bel(x)$ und $Pl(x)$ eines Glaubensintervalls (siehe Abbildung 3.3). Die Subjektive-Logik verwendet daher dieselbe Definition eines Betrachtungsrahmens Θ . Dieser bildet die Grundlage der Hypothesen bzw. Schlussfolgerungen.




Abbildung 3.3: Zusammenhang zwischen Glaubensintervall und *Binomial-Opinion*

Die übliche Notation für eine *Opinion* ist ω_{Θ}^A . Hierbei ist Θ der Betrachtungsrahmen und A der Betrachter, dessen Meinung über die möglichen Schlussfolgerungen dargestellt wird [Jøs10]. Eine alternative Schreibweise ist: $\omega(A : \Theta)$

Eine *Opinion* besteht aus Glauben, Zweifel, Unsicherheit und der A-priori-Wahrscheinlichkeit bezüglich eines gegebenen Sachverhaltes. Zur Bestimmung eines probabilistischen Wahrscheinlichkeitswertes wird die Unsicherheit mit der A-priori-Wahrscheinlichkeit verrechnet. Die A-priori-Wahrscheinlichkeit, auch als unbedingte Wahrscheinlichkeit bezeichnet, ist eine Wahrscheinlichkeitsverteilung über die möglichen Schlussfolgerungen und basiert auf Erfahrung und Vorwissen des Betrachters. Sie kann unter anderem durch die Auswertung von vorherigen Beobachtungen gewonnen werden. Beispielsweise beträgt die A-priori-Wahrscheinlichkeit für ein Pferd A , das bei den letzten zehn Rennen achtmal gewonnen hat, 80%. Alternativ kann der strukturelle Aufbau der Gegebenheiten zur Bestimmung der A-priori-Wahrscheinlichkeit verwendet werden. Ein Beispiel hierfür ist ein manipulierter Würfel, bei dem eine „1“ doppelt so häufig als Ergebnis auftritt, wie alle anderen Seiten. Auch mit diesem Vorwissen ist es möglich eine entsprechende Verteilung für die A-priori-Wahrscheinlichkeit aufzustellen. Wenn nichts anders angegeben bzw. nichts anderes bekannt ist, wird die A-priori-Wahrscheinlichkeit auf einen gleich verteilten Erwartungswert¹¹ gesetzt [Jøs10].

Bezeichnung	Definitionsbereich	Äquivalent
<i>Binomial-Opinion</i>	x und \bar{x}	Binär-Logik
<i>Multinomial-Opinion</i>	$x \in \Theta$	Wahrscheinlichkeitstheorie
<i>Hyper-Opinion</i>	$x \subset \Theta$	Dempster-Shafer-Theorie

Tabelle 3.6: Die verschiedenen Klassen von *Opinions* und ihre zugehörigen Äquivalente.

¹¹Erwartungswert: $\frac{k}{|\Theta|}$; im zweiwertigen Fall somit $\frac{1}{2}$

Alle *Opinions* lassen sich auf unterschiedliche Arten darstellen. Die verschiedenen Darstellungsnotationen sind aber sowohl semantisch als auch mathematisch, völlig äquivalent. Mit ihnen ist es möglich die Eigenschaften der Subjektiven-Logik zu bestimmen und der resultierenden Schlussfolgerungen leichter auszuwerten.

Die klassische Darstellung ist die Glaubensnotation. Diese lässt sich bei einer *Binomial-Opinion*, welche einen zweiwertigen Betrachtungsrahmen besitzt, als Position in einem Dreieck einzeichnen. Im Falle eines dreiwertigen Betrachtungsrahmens beschreibt die Glaubensnotation eine Position innerhalb eines Tetraeders und in den restlichen Fällen die Position im entsprechenden Simplex. Die Glaubensnotation ist deshalb zur Interpretation der Bedeutung einer *Opinion* am besten geeignet.

Die weiteren grundlegenden Eigenschaften und Ideen der Subjektiven-Logik werden im Folgenden mit den *Binomial-Opinions* erklärt, da diese die einfachste Klasse der *Opinions* darstellt.

Die in Tabelle 3.6 aufgeführten *Hyper-Opinions* stellen die derzeit jüngste und allgemeinste Form einer *Opinion* dar. Sie wurden das erste Mal in [Jøs11] erwähnt. Das genannte Dokument stand erst in einer sehr späten Phase dieser Arbeit zur Verfügung. Zu diesem Zeitpunkt waren Recherche, Planung und auch Implementierung bereits abgeschlossen. Da diese zu dem anders definiert sind als die *Binomial-Opinions* und *Multinomial-Opinions* werden sie in diesem Kapitel nicht weiter behandelt. Ihre Eigenschaften werden in Kapitel 4 kurz erläutert.

3.5.2 Binomial-Opinion

Im Falle einer *Binomial-Opinion* ist der Betrachtungsrahmen $\Theta = \{x, \bar{x}\}$. Er wird daher in der Regel weggelassen. Stattdessen ist ω_x^A die übliche Schreibweise für eine *Binomial-Opinion*.

Definition 9 (Binomial-Opinion):

Eine *Binomial-Opinion* ist ein Quadrupel $\omega_x^A = (b, d, u, a)$, bestehend aus dem Glauben $b = Bel(x)$, dem Zweifel $d = Dis(x)$, der Unsicherheit u und der A-priori-Wahrscheinlichkeit a , für den gilt:

$$b + d + u = 1 \text{ und } b, d, u, a \in [0, 1]$$

Dieses Tupel kann – wie eingangs erwähnt – im Falle der *Binomial-Opinion* in einen dreieckigen Raum, der die drei Achsen b , d und u besitzt, eingezeichnet werden [Jøs01]. Dieser wird *Opinion-Simplex* genannt und ist für eine *Binomial-Opinion* in Abbildung 3.4 dargestellt.

Die obere Spitze des Dreiecks entspricht einer maximalen Unsicherheit $u = 1$. Die untere, linke Ecke entspricht einem maximalen Zweifel von $d = 1$, also einem maximalen Glauben,




Abbildung 3.4: *Opinion-Simplex* mit einer eingezeichneten *Binomial-Opinion*

dass die Schlussfolgerung falsch ist. Hingegen entspricht die untere, rechte Ecke einem maximalen Glauben von $b = 1$, dass die Schlussfolgerung wahr ist.

Die horizontale Kante bzw. der Boden des Dreiecks entspricht den Werten der probabilistischen Wahrscheinlichkeitstheorie. *Opinions*, die exakt auf dieser Kante liegen, werden als dogmatisch bzw. starrsinnig bezeichnet, da keine reale Schlussfolgerung eine absolute Sicherheit aufweisen kann.

Die Darstellung ähnelt stark der Kleene-Logik \mathcal{K}_3 . Dieser fehlt allerdings die Eigenschaft der A-priori-Wahrscheinlichkeit, weshalb sie keine Einschätzung bei Unsicherheit angibt. [JM04; JØS10]

Die A-priori-Wahrscheinlichkeit a einer *Binomial-Opinion* ω_x^A wird durch einen Vektor, von der Spitze des Dreiecks zur passenden Position auf dem Boden des Dreiecks, eingezeichnet. Sie wird auch als *Base-Rate* bezeichnet. Parallel zu diesem Vektor wird eine *Opinion* ω_x^A von ihrer Position im *Opinion-Simplex* auf den Boden projiziert. Die daraus resultierende Position entspricht dem Wahrscheinlichkeitswert $E(x)$.

$$E(x) = b + u \cdot a \quad (3.10)$$

Subjektive-Logik bietet somit – im Gegensatz zur Dempster-Shafer-Theorie – eine Definition, wie mit vorhandener Unsicherheit umzugehen ist. Durch diese Eigenschaft ist es möglich, *Opinions* sinnvoll zu vergleichen.

Des Weiteren kann Subjektive-Logik leicht an Stellen eingesetzt werden, an denen zuvor die probabilistische Wahrscheinlichkeitstheorie eingesetzt wurde. Dies kann dahingehend begründet werden, dass der Wert $E(x)$ vergleichbar ist mit einem Wahrscheinlichkeitswert $p(x)$

der probabilistischen Logik. Daraus ergibt sich, im Vergleich zur Dempster-Shafer-Theorie, bei der diese Punkte nicht geklärt sind, ein Vorteil.

3.5.3 Multinomial-Opinion

Wie in Tabelle 3.6 zu sehen ist, stellen *Multinomial-Opinions*, also *Opinions* mit einem Betrachtungsrahmen $|\Theta| > 2$, eine Verallgemeinerung der probabilistischen Logik dar. Hier wird jedem $x \in \Theta$ ein Glaubenswert zugewiesen. Da es sich beim *Opinion-Simplex* um einen mehrdimensionalen Raum handelt, wird die Glaubenszuweisung meist als Glaubensvektor \vec{b} dargestellt. Dieser Vektor kann auch als Vektorfunktion betrachtet werden, die jedem x einen Wert zuordnet. Der Wert von x entspricht der zugehörigen Position entlang des Vektors. Die folgenden Definitionen sind sinngemäß aus [Jøso7] und [JøS10] entnommen:

Definition 10 (Belief Mass Vector):

Sei Θ der Betrachtungsrahmen, dann ist \vec{b} eine Vektorfunktion $\Theta \mapsto [0, 1]^k$, welche die Glaubensverteilung über dem Betrachtungsrahmen darstellt und folgende Eigenschaften erfüllt:

$$\vec{b}(\emptyset) = 0.0 \text{ und } \sum_{x \in \Theta} \vec{b}(x) \leq 1$$

Dies entspricht einer subadditiven¹² Wahrscheinlichkeitsfunktion. Die Additivität wird durch das Hinzufügen der Unsicherheitsmasse wieder hergestellt:

Definition 11 (Uncertainty Mass):

Sei Θ der Betrachtungsrahmen und \vec{b} ein Glaubensvektor, dann ist die Unsicherheit $u \in [0, 1]$ definiert als:

$$u = 1 - \sum_{x \in \Theta} \vec{b}(x)$$

Ähnlich zum Glaubensvektor \vec{b} , lässt sich die A-priori-Wahrscheinlichkeit als Vektorfunktion definieren:

Definition 12 (Base Rate Vector):

Sei Θ der Betrachtungsrahmen, dann ist \vec{a} eine Vektorfunktion $\Theta \mapsto [0, 1]^k$, welche die A-priori-Wahrscheinlichkeit über dem Betrachtungsrahmen darstellt und folgende Eigenschaften erfüllt:

$$\vec{a}(\emptyset) = 0.0 \text{ und } \sum_{x \in \Theta} \vec{a}(x) = 1$$

Der Zweifel d wird bei einer *Multinomial-Opinion* durch die von x verschiedenen Elemente des Glaubensvektors dargestellt. Es muss somit keine Vektorfunktion für ihn definiert werden.

¹²Die Summe der einzelnen Werte kann zusammen weniger als eins ergeben.

Eine *Multinomial-Opinion* lässt sich somit, ähnlich der *Binomial-Opinion* aus Definition 9, wie folgt definieren. Diese Definition stellt, nach A. Jøsang [Jøs11], die allgemeinste Beschreibung einer *Opinion* dar.

Definition 13 (Multinomial Opinion):

Eine *Multinomial-Opinion* ist eine zusammengefasste Funktion $\omega_{\Theta}^A = (\vec{b}, u, \vec{a})$, bestehend aus dem Glauben \vec{b} , der Unsicherheit u und der A-priori-Wahrscheinlichkeit \vec{a} aus Sicht eines Betrachters A über dem Betrachtungsrahmen Θ .




Abbildung 3.5: *Opinion-Simplex* für eine *Multinomial-Opinion*

Analog zur Wahrscheinlichkeitsprojektion aus Gleichung 3.10 auf Seite 37, kann eine *Multinomial-Opinion* auf die Betrachtungsebene des *Opinion-Simplex* projiziert werden, um die Wahrscheinlichkeitswerte der einzelnen Schlussfolgerungen zu erhalten. Dies ist in Abbildung 3.5 für eine *Multinomial-Opinion* mit einem Betrachtungsrahmen Θ der Größe drei dargestellt. Die dazugehörige Definition 14 stellt die zugrundeliegende Gleichung dieser Projektion auf.

Definition 14 (Probability Projection):

Sei Θ der Betrachtungsrahmen der *Opinion* $\omega_{\Theta}^A = (\vec{b}, u, \vec{a})$, dann ist die Wahrscheinlichkeitsprojektion definiert als:

$$\vec{E}(x) = \vec{b}(x) + \vec{a}(x) \cdot u, \quad \forall x \in \Theta$$

Die Wahrscheinlichkeitsprojektion einer *Multinomial-Opinion* ist additiv im Sinne der probabilistischen Wahrscheinlichkeitstheorie, da:

$$\sum_{x \in \Theta} \vec{E}(x) = 1 \quad (3.11)$$

Aus diesem Grund kann sie als Ersatz für eine probabilistische Wahrscheinlichkeitsverteilung verwendet werden.

3.5.4 Darstellungsformen

Neben der Glaubensnotation einer *Opinion* gibt es drei weitere Darstellungsformen bzw. Notationen. Dazu gehört die Evidenz-Notation, die einer Wahrscheinlichkeitsdichtefunktion der Statistik entspricht, die Wahrscheinlichkeitsnotation, die das Ergebnis der Wahrscheinlichkeitsprojektion direkt darstellt und die Darstellung als Fuzzy-Kategorie.

Bei der Fuzzy-Kategorie wird ein Raster mit Begriffen aus der menschlichen Sprache über das *Opinion-Simplex* gelegt. Je nach Quadranten wird ein anderer, in der menschlichen Sprache üblicher, Begriff für Unsicherheit ausgewählt. Diese Notation ist für diese Diplomarbeit unwichtig, weshalb diese hier nicht weiter erklärt wird. Nähere Informationen zur Fuzzy-Kategorie sind in A. Jøsang [Jø10] zu finden.

Die Wahrscheinlichkeitsnotation ist eine sehr einfache und naheliegende Notation, die in vielen Fällen anwendbar ist. Des Weiteren ist die Evidenz-Notation eine sehr wichtige Notation. Sie zeigt, worauf die Subjektive-Logik basiert und wie mächtig sie ist. Daher werden beide genannten Notationen hier kurz umrissen. Nähere Informationen zu diesen Notationen sind in [Jø97], [Jø01], [JPD05] sowie in [Jø11] zu finden.

Wahrscheinlichkeitsnotation

Die Wahrscheinlichkeitsnotation hat den großen Vorteil, dass die Wahrscheinlichkeit einer *Opinion* explizit angegeben wird. Dies kann in vielen Fällen ein großer Vorteil sein, da sowohl die Glaubensnotation als auch die Evidenz-Notation die Wahrscheinlichkeit einer *Opinion* nur implizit angeben. Laut A. Jøsang [Jø10] reduziert dies die Vergleichbarkeit zweier *Opinions*.

Die Notation besteht aus der Wahrscheinlichkeitsprojektion \vec{E} , der A-priori-Wahrscheinlichkeit \vec{a} und der Sicherheit c , definiert als $c = 1 - u$. Mit diesen Angaben wird ein Tripel ähnlich der Definition 13 definiert als $\omega_{\Theta}^{\text{pn}} = (\vec{E}, c, \vec{a})$.

Es lässt sich sehr leicht zeigen, dass eine *Opinion*, die in der Glaubensnotation gegeben ist, in die Wahrscheinlichkeitsnotation überführt werden kann. Hierzu ist es nur nötig die Formel aus Definition 14 wie folgt umzustellen:

$$\left. \begin{array}{l} \vec{E}(x) = \vec{b}(x) + \vec{a}(c) \cdot u \\ c = 1 - u \end{array} \right\} \Leftrightarrow \left\{ \begin{array}{l} \vec{b}(x) = \vec{E}(x) - \vec{a}(c) \cdot u \\ u = 1 - c \end{array} \right. \quad (3.12)$$

Diese Notation bringt prinzipiell keine neuen Erkenntnisse. Sie ist dann sinnvoll, wenn die Angabe der Wahrscheinlichkeit und der dazugehörigen Sicherheit im Vordergrund stehen und die Angabe von Glauben, Zweifel und Unsicherheit nur zweitrangig ist.

Evidenz-Notation

Aus mathematischer Sicht ist die Evidenz-Notation sowohl die interessanteste, als auch die komplizierteste Notation. Die einzelnen Werte können nicht direkt – wie bei der Glaubensnotation oder der Wahrscheinlichkeitsnotation – abgelesen werden. Mit ihrer Hilfe ist es jedoch möglich, eine *Opinion* in eine Dirichlet-Verteilung zu überführen. Im Falle einer *Binomial-Opinion* ist dies eine Beta-Verteilung.

Beide Verteilungen entsprechen einer Wahrscheinlichkeitsverteilung zweiter Ordnung. Sie geben an, wie wahrscheinlich eine Wahrscheinlichkeitsverteilung ist.

Nach A. Jøsang [Jøs07] kann die Dirichlet-Verteilung, mithilfe der Γ -Funktion, wie folgt definiert werden.

Definition 15 (Dirichlet-Verteilung):

Sei Θ der Betrachtungsrahmen, $\vec{\alpha}$ der Evidenz-Vektor für die Elemente von Θ und \vec{p} der Wahrscheinlichkeitsvektor. Eine multivariate Dirichlet-Dichtefunktion ist somit:

$$f(\vec{p}|\vec{\alpha}) = \frac{\Gamma\left(\sum_{i=1}^k \alpha(x_i)\right)}{\prod_{i=1}^k \Gamma(\alpha(x_i))} \prod_{i=1}^k p(x_i)^{\alpha(x_i)-1} \quad \text{und} \quad \forall x \in \Theta : \alpha(x) \geq 0.$$

Der Vektor $\vec{\alpha}$ enthält hier sowohl die A-priori-Wahrscheinlichkeit \vec{a} als auch die beobachtete Evidenz. Er muss daher in zwei Parameter aufgeteilt werden, um die *Opinion* in eine Dirichlet-Verteilung überführen zu können.

$$\vec{\alpha}(x_i) = \vec{r} + W \cdot \vec{a}(x_i) \quad \text{mit} \quad \begin{cases} \forall x \in \Theta : \vec{r}(x) \geq 0 \\ \forall x \in \Theta : \vec{a}(x) \in [0 : 1] \\ \sum_{x \in \Theta} \vec{a}(x_i) = 1 \\ W \geq 2 \end{cases} \quad (3.13)$$

Der Vektor \vec{r} aus Gleichung 3.13 ist die beobachtete Evidenz und entspricht in etwa dem Glaubensvektor \vec{b} einer *Opinion*. Als Folge der Aufteilung in A-priori-Wahrscheinlichkeit und beobachtete Evidenz ist es möglich, die Evidenz-Notation aufzustellen [Jøs07; Jøs10].

Definition 16 (Evidenz-Notation):

Sei Θ der Betrachtungsrahmen mit einer Dirichlet-Verteilung $f(\vec{p}|\vec{r}, \vec{a})$. Die Evidenz-Notation ist dann ein Tupel der Form $\omega_{\Theta}^{\text{en}} = (\vec{r}, \vec{a})$. Im Falle einer *Binomial-Opinion* ist $\omega_{\Theta}^{\text{en}} = (r, s, a)$ die übliche Schreibweise.

Die Umwandlung zwischen *Opinions* in Glaubensnotation und *Opinions* in Evidenz-Notation erfolgt über den Wahrscheinlichkeitswert $\vec{E}(x)$.

Bei der Glaubensnotation wird dieser über die Formel aus Definition 14 bestimmt. Für eine Dirichlet-Verteilung hingegen gilt folgende Formel:

$$\vec{E}(\vec{p}(x_i)|\vec{r}, \vec{a}) = \frac{\vec{r}(x_i) + W \cdot \vec{a}(x_i)}{W + \sum_{x \in \Theta} \vec{r}(x)} \quad (3.14)$$

Mithilfe dieser beiden Gleichungen und der Eigenschaft, dass bei steigendem Glauben die Unsicherheit sinkt, lässt sich zeigen, dass zwei *Opinions* in Glaubensnotation und in Evidenz-Notation gleich sind, wenn gilt:

$$\left. \begin{array}{l} \vec{b}(x) = \frac{\vec{r}(x)}{W + \sum_{x \in \Theta} \vec{r}(x)} \\ u = \frac{W}{W + \sum_{x \in \Theta} \vec{r}(x)} \end{array} \right\} \Leftrightarrow \left\{ \begin{array}{l} \vec{r}(x) = \frac{W\vec{b}(x)}{u} \\ 1 = u + \sum_{x \in \Theta} \vec{b}(x) \end{array} \right. \quad (3.15)$$

Für dogmatische *Opinions* ($u = 0$) kann diese Gleichung allerdings nicht verwendet werden, da dies zu einer Division durch null führen würde. Dieser Sonderfall benötigt weitere Schritte und wird in [JØS10] ausführlich beschrieben.

Die Überführung von *Opinions* in Dirichlet-Verteilungen bildet die mathematische Grundlage der zahlreichen Operatoren der Subjektiven-Logik. Viele dieser Operatoren arbeiten entweder direkt auf Basis der Dirichlet-Verteilungen und Dichtefunktionen oder sind effiziente Näherungen, da die korrekte Berechnung zu aufwändig bzw. unmöglich wäre. Durch die Evidenznotation ist es möglich die Operatoren auf Korrektheit zu prüfen, ebenso kann dadurch gezeigt werden das *Opinions* Wahrscheinlichkeitsverteilungen zweiter Ordnung entsprechen.

Zur besseren Veranschaulichung der einzelnen Notationen sind in der Tabelle 3.7 einige *Binomial-Opinions* in verschiedenen Notationen aufgeführt.

3.5.5 Operatoren

Für die Subjektive-Logik sind zahlreiche mathematische Operatoren definiert. Tabelle 3.8 zeigt eine Übersicht diverser Operatoren. Die meisten entsprechen ihren mathematischen Äquivalenten aus der Binär-Logik sowie der klassischen Wahrscheinlichkeitstheorie. Es gibt aber auch spezielle Operatoren, die es nur in der Subjektiven-Logik gibt.

FlowCon verwendet neben der Ableitung im Bayes'schen Netz die Konjunktion \wedge , Disjunktion \vee und Negation \neg für die Auswertung der Transitionsbedingungen.

Um die Verwendungsmöglichkeiten der Subjektiven-Logik für FlowCon besser beurteilen zu können, werden die genannten Operatoren sowie deren Funktionsweise im Folgenden kurz erläutert. Ebenso wird geprüft ob das Bayes'sche Netz durch die Abduktion und Deduktion der Subjektiven-Logik erweitert werden kann.

Glauben	Notation		Interpretation
	Evidenz	Wahrscheinlich	
(b, d, u, a)	(r, s, a)	(E, c, a)	
$(1, 0, 0, a)$	$(\infty, 0, a)$	$(1, 1, a)$	Wahr in der Binär-Logik bzw. $p = 1$ als Wahrscheinlichkeit
$(0, 1, 0, a)$	$(0, \infty, a)$	$(0, 1, a)$	Falsch in der Binär-Logik bzw. $p = 0$ als Wahrscheinlichkeit
$(0, 0, 0, a)$	$(0, 0, a)$	$(a, 0, a)$	Leere Behauptung, Beta-Verteilung mit Vorbelegung a
$(\frac{1}{2}, \frac{1}{2}, 0, a)$	(∞, ∞, a)	$(\frac{1}{2}, 1, a)$	Dogmatische <i>Opinion</i> mit $p = \frac{1}{2}$ bzw. Dirac-Delta-Funktion.
$(0, 0, 1, \frac{1}{2})$	$(0, 0, \frac{1}{2})$	$(\frac{1}{2}, 0, \frac{1}{2})$	Leere Behauptung, uniforme Beta-Verteilung mit binärem Betrachtungsrahmen
$(\frac{1}{4}, \frac{1}{4}, \frac{1}{2}, \frac{1}{2})$	$(1, 1, \frac{1}{2})$	$(\frac{1}{2}, \frac{1}{2}, \frac{1}{2})$	Symmetrische Beta-Verteilung mit binärem Betrachtungsrahmen, nach einer positiven und einer negativen Beobachtung

Tabelle 3.7: *Binomial-Opinions* in verschiedenen Notationen [Jøs10]

Subjektive-Logik	Vergleichbar mit ^a		Notation
Addition	+	XOR	\cup $\omega_{x \cup y} = \omega_x + \omega_y$
Subtraktion	-	Differenz	\setminus $\omega_{x \setminus y} = \omega_x - \omega_y$
Multiplikation	·	AND	\wedge $\omega_{x \wedge y} = \omega_x \cdot \omega_y$
Division	/	NAND	$\bar{\wedge}$ $\omega_{x \bar{\wedge} y} = \omega_x / \omega_y$
Komultiplikation	\sqcup	OR	\vee $\omega_{x \vee y} = \omega_x \sqcup \omega_y$
Komplement	\neg	NOT	\bar{x} $\omega_{\bar{x}} = \neg \omega_x$
Deduktion	\odot	MP	\parallel $\omega_{Y \parallel X} = \omega_X \odot \omega_{Y X}$
Abduktion	$\overline{\odot}$	MT	$\overline{\parallel}$ $\omega_{Y \overline{\parallel} X} = \omega_X \overline{\odot} \omega_{X Y}$

Tabelle 3.8: Verschiedene Operatoren der Subjektiven-Logik [Jøs10]

^aOperatoren aus der Binär-Logik bzw. Mengen-Theorie

Konjunktion

Die Konjunktion zweier *Opinions* ist, wie die Konjunktion zweier Wahrscheinlichkeiten, als Multiplikation $\omega_{x \wedge y} = \omega_x \cdot \omega_y$ definiert. Die ursprüngliche Form basierte auf einem einfachen und intuitiven Ansatz: Bei einer Konjunktion müssen beide Aussagen wahr sein. Es genügt, wenn eine Aussage falsch ist, damit das Ergebnis falsch ist. Dieser Ansatz entspricht der Konjunktion der Vier-Wertigen-Logik. Er ist ebenfalls eine Verallgemeinerung der Drei-Wertigen-Logik \mathcal{K}_3 von Kleene [JM04].

Zur Bestimmung des Glaubens b der konjugierten *Opinion* $\omega_{x \wedge y}$ wird der Glaube der beiden *Opinions* ω_x und ω_y multipliziert ($b_{x \wedge y} = b_x \cdot b_y$). Den Zweifel d der neuen *Opinion* $\omega_{x \wedge y}$ bestimmt die Subjektive-Logik hingegen über das Koproduct der beiden Zweifelswerte ($d_{x \wedge y} = d_x + d_y - d_x \cdot d_y$). Die Definition der Unsicherheit ergibt sich aus der Bedingung $1 = b + d + u$. Zum Schluss wird die A-priori-Wahrscheinlichkeit so definiert, dass $E(x \wedge y) = E(x) \cdot E(y)$ gilt, um mit der probabilistischen Wahrscheinlichkeitstheorie übereinzustimmen. [JM04; Jø97]

Dieser einfache Ansatz bringt diverse Probleme [JM04]: Zum einen ist die A-priori-Wahrscheinlichkeit abhängig von den aktuellen Glaubens- und Zweifelswerten der Gegenwart, zum anderen gibt es eine starke Abweichung zur Konjunktion der Dirichlet-Verteilungen.

Aufgrund dessen wird das Produkt zweier *Opinions* neu definiert. Bei dieser Definition hängt die A-priori-Wahrscheinlichkeit nur noch von den A-priori-Wahrscheinlichkeiten der ursprünglichen *Opinions* ab. Hierzu werden die restlichen Gleichungen zur Bestimmung der Werte b , d und u leicht angepasst. Sie sind in der folgenden Gleichung 3.16 zu sehen. Nähere Informationen zur Herleitung sind in [JM04] und [Jø10] zu finden.

$$\text{Produkt } \omega_{x \wedge y} = \begin{cases} b_{x \wedge y} &= b_x b_y + \frac{(1-a_x)a_y b_x u_y + a_x(1-a_y)u_x b_y}{1-a_x a_y} \\ d_{x \wedge y} &= d_x + d_y - d_x d_y \\ u_{x \wedge y} &= u_x u_y + \frac{(1-a_y)b_x u_y + (1-a_x)u_x b_y}{1-a_x a_y} \\ a_{x \wedge y} &= a_x a_y \end{cases} \quad (3.16)$$

Die Subjektive-Logik stellt eine Verallgemeinerung der probabilistischen Wahrscheinlichkeitstheorie dar. Deshalb gilt auch in dieser Definition der Konjunktion $E(x \wedge y) = E(x) \cdot E(y)$, wodurch die Konjunktion der Subjektiven-Logik der Multiplikation zweier Wahrscheinlichkeiten entspricht. [JM04]

Disjunktion

Die Disjunktion entspricht dem Koproduct der Wahrscheinlichkeitstheorie bzw. der Oder-Verknüpfung der Binär-Logik. Ähnlich der Konjunktion gab es eine einfache ursprüngliche Fassung dieses Operators. Da die Disjunktion auf demselben Ansatz basierte, wies sie

dieselben Probleme auf. So wurde auch die Disjunktion neu definiert, um eine bessere Näherung für die vergleichbaren Operatoren der Dirichlet-Verteilung zu erhalten.

Die folgende Gleichung 3.17 zeigt die neue Definition der Disjunktion [JM04]:

$$\text{Koprodukt } \omega_{x \vee y} = \begin{cases} b_{x \vee y} &= b_x + b_y - b_x b_y \\ d_{x \vee y} &= d_x d_y + \frac{a_x(1-a_y)u_y d_x + (1-a_x)a_y u_x d_y}{a_x + a_y - a_x a_y} \\ u_{x \vee y} &= u_x u_y + \frac{a_x u_x d_y + a_y u_y d_x}{a_x + a_y - a_x a_y} \\ a_{x \vee y} &= a_x + a_y - a_x a_y \end{cases} \quad (3.17)$$

Auch bei der Disjunktion gilt, dass der projizierte Wahrscheinlichkeitswert der neuen *Opinion* $\omega_{x \vee y}$ der Disjunktion der projizierten Wahrscheinlichkeitswerte von ω_x und ω_y entspricht.

$$E(x \vee y) = E(x) + E(y) - E(x) \cdot E(y) \quad (3.18)$$

Negation

Die Negation bildet eine *Opinion* auf ihre komplementäre *Opinion* ab. Das Vorgehen entspricht ebenfalls der Kleene-Logik \mathcal{K}_3 , bei der sich nur die Wahrheitswerte vertauschen. Die Definition ähnelt daher der neuen Negation \neg der Vier-Wertigen-Logik.

Es werden – im Vergleich zur ursprünglichen *Opinion* – nur der Glaubenswert b und der Wert des Zweifels d in der resultierenden *Opinion* vertauscht. Die Unsicherheit bleibt dieselbe.

Als Letztes wird die A-priori-Wahrscheinlichkeit a der negierten *Opinion* $\neg \omega_x^A$ über die Negation der Wahrscheinlichkeitstheorie $p(\bar{x}) = 1 - p(x)$ bestimmt.

Die vollständige Definition des Komplements ist in der folgenden Gleichung zu sehen [Jø01; Jø10].

$$\text{Komplement } \neg \omega_x \equiv \omega_{\bar{x}} \equiv \omega_{\neg x} = \begin{cases} b_{\neg x} &= d_x \\ d_{\neg x} &= b_x \\ u_{\neg x} &= u_x \\ a_{\neg x} &= 1 - a_x \end{cases} \quad (3.19)$$

Inferenzregeln

Zum Schlussfolgern und Ableiten besitzt die Binär-Logik einige Inferenzregeln. Die beiden Bekanntesten sind: der Modus-Ponens (MP) sowie der Modus-Tollens¹³ (MT) [Jø08].

$$MP : \{x \rightarrow y, x\} \Rightarrow y \quad (3.20)$$

$$MT : \{x \rightarrow y, \bar{y}\} \Rightarrow \bar{x} \quad (3.21)$$

¹³eigentlich Modus-Tollendo-Tollens

In der Wahrscheinlichkeitstheorie gibt es hierfür die probabilistische Inferenz. Diese verwendet bedingte Wahrscheinlichkeiten der Form $P(a|b)$, welche der Aussage, „Die Wahrscheinlichkeit von a , vorausgesetzt, dass nur b bekannt, ist ...“ entsprechen. [RNo4, Seite 578]

Meist ist die bedingte Wahrscheinlichkeit $P(a|b)$ bekannt, es wird aber die Wahrscheinlichkeit $P(b|a)$ benötigt. Dieses Problem wird mithilfe der Bayes’schen Regel gelöst, welche in Gleichung 3.22 dargestellt ist.

$$P(\mathcal{B}|\mathcal{A}) = \frac{P(\mathcal{A}|\mathcal{B}) \cdot P(\mathcal{B})}{P(\mathcal{A})} \quad (3.22)$$

Sie bildet die Grundlage für viele KI-basierte Systeme. Speziell Bayes’sche Netze arbeiten mit diesem Theorem [RNo4, Kapitel 13–14].

Die Gleichungen 3.23 und 3.24 zeigen die subjektive-Logik-Operatoren für Deduktion und Abduktion. Diese erweitern die Inferenzregeln der probabilistischen Logik derart, dass sowohl für die Eingabeparameter als auch für die Ausgabe *Opinions* verwendet werden [JøS10].

$$\omega_{Y||X} = \omega_X \odot \omega_{Y|X} \quad (3.23)$$

$$\omega_{Y||\bar{X}} = \omega_X \overline{\odot} \omega_{X|Y} \quad (3.24)$$

Es ist dadurch möglich, die zugrundeliegende Unsicherheit in die Inferenz mit einfließen zu lassen. Das Ergebnis enthält zusätzlich eine Angabe, wie hoch die Unsicherheit des resultierenden Inferenzergebnisses ist [JøS08].




Abbildung 3.6: Projektion des *Opinion-Dreiecks* [JøS10]

Um dies zu ermöglichen, wird das *Opinion-Simplex* der Eingabe ω_X in das *Opinion-Simplex* der Ausgabe $\omega_{Y|X}$ projiziert. Die Position der *Opinion* ω_X wird anschließend in das projizierte

Simplex übertragen und entspricht der berechneten *Opinion* $\omega_{Y|X}$. Abbildung 3.6 zeigt eine solche Projektion für den zweiwertigen Fall.

Zu beachten ist, dass nur $\omega_{Y|X}$ und ω_X gegeben sind. Zur Bestimmung der Position der Unsicherheit wird das Ergebnis einer leeren Behauptung $\omega_{\hat{x}}$ berechnet und entsprechend projiziert.

Die Projektion muss nicht unbedingt ein gleichseitiges Dreieck ergeben. Das entstehende Simplex kann beliebig verdreht oder verzerrt sein, sodass die leere Behauptung $\omega_{\hat{x}}$ beispielsweise unterhalb der beiden anderen Punkte liegt und somit weniger Unsicherheit aufweist. Ebenso kann eine sehr wahrscheinliche *Opinion* zu einer sehr unwahrscheinlichen *Opinion* führen. Dies wäre beispielsweise der Fall, wenn anhand der Wetterprognose auf den Ausgang eines Pferderennens geschlossen wird. Sagt die Wetterprognose hier mit einer sehr hohen Sicherheit ein Unwetter voraus, ist das Ergebnis des Rennens völlig ungewiss, da die Favoriten nicht unbedingt an den Start gehen.

Zur Berechnung der Abduktion wird die *Opinion* $\omega_{Y|x_i}$ benötigt, welche aus der *Opinion* $\omega_{X|y_i}$ berechnet werden muss. Die probabilistische Wahrscheinlichkeitstheorie verwendet hierfür die Bayes'sche Regel, welche eine Division enthält. Die Division der Subjektiven-Logik ist aber nur für *Binomial-Opinions* sinnvoll berechenbar. Deswegen geht die Abduktion der Subjektiven-Logik einen anderen Weg.

Die projizierten Wahrscheinlichkeitswerte $\vec{E}(x)$ werden analog zur probabilistischen Wahrscheinlichkeitstheorie berechnet. Die fehlende Unsicherheit der *Opinion* wird anschließend über Unsicherheitsmaximierung [Jø808; Jø810] bestimmt. Bei diesem Vorgang wird die *Opinion* mit der größten Unsicherheit $\hat{\omega}_{Y|x_i}$, die für den Wahrscheinlichkeitswert E in Kombination mit der gegebenen A-priori-Wahrscheinlichkeit a , möglich ist, bestimmt. Abbildung 3.7 veranschaulicht dieses Vorgehen graphisch.




Abbildung 3.7: Unsicherheitsmaximierung einer dogmatischen *Opinion* [Jø810]

Durch die Abduktion und Deduktion der Subjektiven-Logik lässt sich erkennen, ob die resultierende Wahrscheinlichkeit aufgrund von Glauben entstanden ist, oder aufgrund von

Unsicherheit. Dies kann einen entscheidenden Unterschied ausmachen. Ein Beispiel hierfür sowie nähere Details und die genauen Berechnungsvorschriften sind in A. Jøsang [Jøs08]; A. Jøsang, S. Pope und M. Daniel [JPD05] und A. Jøsang [Jøs10] zu finden.

3.5.6 Verwendungsmöglichkeiten in FlowCon

Die Unsicherheit und das Vorwissen des Betrachters spielen eine große Rolle in der Subjektiven-Logik. Zusammen mit der Einschätzung des Betrachters bilden sie eine *Opinion*, die in verschiedenen Notationen dargestellt werden kann. Die Glaubensnotation ist durch die Darstellung in einem Dreieck bzw. Simplex für einen Anwender leicht interpretierbar (Anforderung A-4). Ebenso sind *Opinions* durch die Wahrscheinlichkeitsnotation leicht vergleichbar (Anforderung A-3), da sie einen Wahrscheinlichkeitswert besitzen, der mit der probabilistischen Logik übereinstimmt.

Die Subjektive-Logik bietet eine große Menge an Operatoren. Darunter sind auch die, durch Anforderung A-6 geforderten, Operatoren für die Konjunktion, Disjunktion und Negation. Mit diesen können Transitionsbedingungen entsprechend der Subjektiven-Logik modelliert werden, da die entstehenden *Opinions* anhand von Kriterien ausgewertet werden können (Anforderung A-2).

Die Operatoren arbeiten auf Dirichlet-Verteilungen. Im Gegensatz zur Dempster'schen Kombinationsregel liefern sie daher intuitive und nachvollziehbare Ergebnisse und erfüllen Anforderung A-5 vollständig.

In der Glaubensnotation und in der Wahrscheinlichkeitsnotation wird die Unsicherheit explizit angegeben. Sie berücksichtigen, ebenso wie die Operatoren, die Unsicherheit des Betrachters, weshalb Anforderung A-1 erfüllt ist.

Wie in Anforderung A-7 verlangt, ist eine probabilistische Inferenz mit Unsicherheit möglich und dadurch eine Erweiterung des Bayes'schen Netzes [Jøs11, Seite 72–75]. Dank der Unsicherheitsangabe der Schlussfolgerung wird das Resultat des Bayes'schen Netzes klarer, was die weitere Auswertung des Ergebnisses vereinfacht.

Die Subjektive-Logik bietet des Weiteren einen Operator zur Fusion zweier *Opinions* [JMP06]. Mit diesem kann eine *Opinion*, die vom Bayes'sche Netz geliefert wird, mit der *Opinion* des Kontext-Managementsystems verbunden werden. Anforderung A-8 ist daher erfüllt.

Alle von FlowCon verwendeten Operatoren – bis auf die Inferenz – weisen keine Eigenschaft auf, welche die Komplexität und somit den Rechenaufwand übermäßig steigert (Anforderung A-9).

Die Inferenz weist, neben der Komplexität, noch andere Probleme auf. Zum einen sprengt das Erweitern des Bayes'schen Netzes den Rahmen dieser Diplomarbeit, da es – ebenso wie das verwendete Framework WEKA [WHR10] – um die Subjektive-Logik erweitert werden

müsste. Des Weiteren erfordert dieser Ansatz eine Bestimmung der A-priori-Wahrscheinlichkeit für die *Opinion* des Kontext-Managementsystems und für die *Opinion* des Bayes'schen Netzes. Die Verteilung des Bayes'schen Netzes entspricht jedoch der A-priori-Wahrscheinlichkeit der vom Kontext-Managementsystem gelieferten *Opinion*. Somit ist eine Erweiterung des Bayes'schen Netzes und die Verwendung der Deduktion bzw. Abduktion hier nicht sinnvoll.

Die beiden Inferenzregeln sollten vom Klassifikator des Kontextmanagementsystems verwendet werden, um die Unsicherheit, die bei der Abbildung von Sensorwerten auf Ereignisse entsteht, zu bestimmen.

Für eine *Opinion* braucht man allgemein eine Verteilung der A-priori-Wahrscheinlichkeit und eine subadditive Verteilung, die dem Glauben \vec{b} entspricht. Die Wahrscheinlichkeitsverteilung des Bayes'schen Netzes kann als A-priori-Wahrscheinlichkeit angesehen werden und die Verteilung des Kontextmanagementsystems entspricht dem Glauben. Da eine *Opinion* einer Dirichlet-Verteilung entspricht, werden durch dieses Vorgehen die Verteilungen des Kontext-Managementsystems auf Wahrscheinlichkeitsverteilungen zweiter Ordnung erweitert.

Die Verteilungen des Kontextmanagementsystems von FlowCon sind auf eins normiert und weisen daher keinerlei Unsicherheit im Sinne der Subjektiven-Logik auf. Die entstehenden *Opinions* wären folglich alle dogmatisch. Eine Unsicherheitsmaximierung – wie bei der Abduktion – würde zwar Unsicherheit erzeugen, die projizierten Wahrscheinlichkeitswerte entsprächen aber den Wahrscheinlichkeitswerten des Kontext-Managementsystems. Eine solche Unsicherheitsbestimmung bringt keinen direkten Nutzen¹⁴, weshalb an dieser Stelle eine andere Lösung gefunden werden muss.

Es gibt Kontextmanagementsysteme, die zusätzlich eine Qualitätsangabe der Kontextinformation liefern. Diese Angabe entspricht aber nicht unbedingt der Unsicherheit der Subjektiven-Logik. Eine Erweiterung, die *Multinomial-Opinions* als Eingabe voraussetzt, schränkt die Anzahl der möglichen Kontextmanagementsysteme stark ein. Die Anforderung A-11 ist in einem solchen Fall nicht erfüllt.

Das Ellsberg-Paradoxon kann mit der Dempster-Shafer-Theorie kompakter dargestellt werden als mit der Subjektiven-Logik. Dies liegt daran, dass die Unsicherheit in der Subjektiven-Logik global ist. Sie betrifft alle Elemente des Betrachtungsrahmens. Im Ellsbergs-Paradoxon herrscht aber keine Unsicherheit über die Wahrscheinlichkeit einer roten Kugel. Eine solche Abstufung ist bei den *Multinomial-Opinions* der Subjektiven-Logik, im Gegensatz zur Dempster-Shafer-Theorie, nicht möglich. Es gibt bei diesen nur eine globale Unsicherheit. Für die Darstellung des Ellsberg-Paradoxons muss deshalb für jede Wette eine *Binomial-Opinion* erstellt werden. Die Anforderung A-10 ist somit nur bedingt erfüllt.

Für die allgemeine Darstellung der von einem beliebigen Kontextmanagementsystem überlieferten Information ist die Subjektive-Logik ungeeignet.

¹⁴Im Falle von FlowCon sogar eine Verschlechterung

3.6 Zusammenfassung

Keins der behandelten Unsicherheitsmodelle erweist sich, für den Einsatz mit FlowCon, als hundertprozentig geeignet. Am besten erfüllt die Subjektive-Logik die in Kapitel 3.2 gestellten Anforderungen. Sie hat alle geforderten Operatoren. Die Ergebnisse und *Opinions* haben eine klar definierte Interpretation. Ebenso sind sie auswertbar und vergleichbar. Dieses Modell schränkt aber die möglichen Kontext-Managementsysteme für FlowCon sehr stark ein. Kein solches gängiges System übergibt eine *Multinomial-Opinion* oder gar eine Liste von *Binomial-Opinions* für jede einzelne Schlussfolgerung. Zur Eingabe ist dieses Modell daher ungeeignet.

Als Eingabe hingegen eignet sich die Dempster-Shafer-Theorie, da sie ursprünglich zur Darstellung von Unsicherheit entwickelt wurde. Mit ihr kann die vorhandene Unsicherheit – im Vergleich zu den anderen Modellen – am genauesten beschrieben werden. Allerdings gestalten die hohe Komplexität und die unintuitiven Ergebnisse der Dempster'schen Kombinationsregel eine Verwendung innerhalb von FlowCon sehr schwierig. Durch die Dempster-Shafer-Theorie steigt die Anzahl an Wahrscheinlichkeitszuweisungen und die Anzahl der Knoten im Bayes'schen Netz exponentiell an. Das verwendete Framework WEKA kollabiert bei einer solch immensen Knotenanzahl. Diese hat für die Bestimmung der exakten A-priori-Wahrscheinlichkeit einen exponentiellen Berechnungsaufwand, der direkt von der Knotenanzahl n abhängt. Der Berechnungsaufwand liegt daher in $\mathcal{O}(2^n)$ mit $n = |2^\Theta|$. Eine solcher Berechnungsaufwand ist auf einem mobilen Gerät nicht mehr möglich.

Es bleibt offen, wie die – an den Transitionsbedingungen entstehenden – Glaubensintervalle ausgewertet werden sollen. Dies ist zwar prinzipiell möglich, eine Vorgabe – wie die Werte zu interpretieren sind – gibt es in der ursprünglichen Fassung jedoch nicht [Sha92].

Zur Auswertung der Transitionsbedingungen eignet sich neben der Subjektiven-Logik auch die Vier-Wertige-Logik. Diese hat die nötigen Operatoren, die zur Auswertung der Transitionsbedingungen benötigt werden. Durch die beiden Ordnungen des Bilattice sind die Werte untereinander vergleichbar. Auch die Ergebnisse sind daher auswertbar und vergleichbar. Zur inneren Verarbeitung der Eingabe des Kontext-Managementsystems und der Verteilung des Bayes'schen Netzes eignet sich die Vier-Wertige-Logik allerdings nicht. Ihr Einsatzgebiet ist ganz klar die Auswertung von Anfragen, welche miteinander verknüpft sind.

Tabelle 3.9 zeigt eine Gegenüberstellung der vorgestellten Unsicherheitsmodelle.

Anforderung		Dempster-Shafer-	Vier-Wertige-	Subjektive
Nr.	Stichwort	Theorie	Logik	Logik
A-1	Unsicherheit	✓	✓	✓
A-2	Auswertbar	✓	✓	✓
A-3	Vergleichbar	✗	✓	✓
A-4	Interpretierbar	✗	✓	✓
A-5	Intuitiv	✗	✓	✓
A-6	Operatoren	✓ ¹	✓	✓
A-7	Inferenzregeln	✓ ¹	✗	✓
A-8	Komb. Bayes.-Netz	✓	✗	✓
A-9	Komplexität	✗	✓	✓
A-10	Ellsberg	✓	✗	✓ ²
A-11	Kontext-Management.	✓	✗	✗

¹ In Erweiterungen vorhanden

² Nicht mit einer einzelnen *Multinomial-Opinion*

Tabelle 3.9: Übersicht der Unsicherheitsmodelle und der erfüllten Anforderungen

4 Hyper-FlowCon

4.1 Integration der Subjektiven-Logik

Aus Kapitel 3 geht hervor, dass sich die Subjektive-Logik von den vorgestellten Unsicherheitsmodellen am besten in FlowCon integrieren lässt. Der folgende Abschnitt befasst sich deshalb damit, wie sie integriert werden kann, ohne dabei zu starke Anforderungen an das zu verwendende Kontext-Managementsystem zu stellen.

4.1.1 Überlegungen

Die Subjektive-Logik eignet sich in fast allen Bereichen als Erweiterung für FlowCon. Es bleiben aber einige Punkte offene. Der kritische Punkt ist, dass kein gängiges Kontext-Managementsystem eine *Multinomial-Opinion* liefert. Stattdessen sind – wenn überhaupt – Bayes'sche Wahrscheinlichkeitsverteilungen oder das wahrscheinlichste Ereignis bzw. die wahrscheinlichste Schlussfolgerung üblich.

Mithilfe der Glaubenszuweisungen aus der Dempster-Shafer-Theorie lassen sich, wie das Ellsberg-Paradoxon gezeigt hat, Wahrscheinlichkeitsverteilungen und Angaben, die aus nur einem Wert bestehen, darstellen. Im Allgemeinen ist eine Glaubenszuweisung als Eingabe ausgesprochen sinnvoll, da die Unsicherheit sehr detailliert und genau angegeben werden kann, ohne die möglichen Kontext-Managementsysteme einzugrenzen. Da FlowCon in der ursprünglichen Form von einer Wahrscheinlichkeitsverteilung als Eingabe ausgeht, würde eine Erweiterung – die Glaubensintervalle als Eingabe verwendet – die Auswahl der möglichen Kontext-Managementsystem sogar erhöhen.

Zur inneren Verarbeitung hingegen ist eine solche Glaubenszuweisung wie in Kapitel 3.6 festgestellt wurde, ungeeignet. Das Bayes'sche Netzwerk gibt lediglich eine klassische Wahrscheinlichkeitsverteilung zurück. Eine solche Verteilung führt in Verbindung mit der Dempster'schen Kombinationsregel jedoch zu unintuitiven Ergebnissen. Die Möglichkeit einer Erweiterung des Bayes'schen Netzwerkes würde zu Komplexitätsproblemen führen. Deshalb kann die Information des Bayes'schen Netzwerkes nicht unmittelbar mit einer Glaubenszuweisung, die von dem Kontextmanagementsystem geliefert wurde, verknüpft werden. Dennoch wäre es sinnvoll, eine Glaubenszuweisung als Eingabe zu verwenden, und diese dann mithilfe der Subjektiven-Logik auszuwerten. Dazu ist es erforderlich eine

Glaubenszuweisung auf eine *Opinion* abzubilden. Dies ist prinzipiell möglich. In älteren Arbeiten von A. Jøsang [Jøs97] werden *Binomial-Opinions* unter Zuhilfenahme von Glaubenszuweisungen definiert. Dabei wird der Betrachtungsrahmen Θ in zwei Partitionen X und \bar{X} aufgeteilt, wodurch man die beiden bekannten Grenzen eines Glaubensintervalls erhält. Wie in Kapitel 3.5 erklärt wurde, entsprechen diese Grenzen dem Glaubenswert b und dem Zweifelswert d einer *Binomial-Opinion*. Allerdings ist nicht von Anfang an bekannt, wie eine Glaubenszuweisung partitioniert werden muss. Dies ist auch nicht erforderlich. Erst der *Condition-Evaluator*, der die Bedingungen der Transitionen auswertet, benötigt eine Angabe zu einem Ereignis in einem – von ihm auswertbaren – Unsicherheitsmodell.

Die Angabe des Ereignisses bzw. der Aktivität des Benutzers ist, wie in Gleichung 2.1 auf Seite 13 dargestellt, Teil einer Transitionsbedingung. Diese Gleichung entspricht einem Ereignisknoten, mit dem die Transitionsbedingung modelliert wird. An diesem Knoten wird eine *Event-Instance* bezüglich eines konkreten Ereignisses bzw. Aktivität des Benutzers ausgewertet.

4.1.2 Umsetzung

Die ursprüngliche Implementierung liefert als Rückgabe einer *Event-Instance* einen klassischen Wahrscheinlichkeitswert zurück (siehe Definition 1 auf Seite 12). Er wird aus der Verteilung Q^{BN} des Bayes'schen Netzes und der Verteilung Q^{CMS} des Kontext-Managementsystems bestimmt. Die beiden Verteilungen werden im Vorfeld gemittelt. Bei der Abfrage am Ereignisknoten wird die Wahrscheinlichkeit des entsprechenden Eintrags aus der Verteilung zurückgegeben.

Durch die Angabe eines konkreten Ereignisses e ist es alternativ möglich, aus einer vom Kontext-Managementsystem bereitgestellten Glaubenszuweisung, ein Glaubensintervall zu bestimmen. Die Grenzen des Intervalls kann man, wie bereits erwähnt, als Glauben und Zweifel einer *Binomial-Opinion* ansehen. Zum selben Ereignis lässt sich, unter Verwendung der Verteilung des Bayes'schen Netzwerks Q^{BN} , die zugehörige A-priori-Wahrscheinlichkeit a bestimmen. Zusammen ergibt dies eine vollständige *Binomial-Opinion* ω_e^A .

Dieses Vorgehen lässt sich, entsprechend der Dempster-Shafer-Theorie, nochmals erweitern. Statt ein Glaubensintervall nur für ein einzelnes Ereignis e zu bestimmen, kann man dies auch für eine Menge von Ereignissen tun. Hierzu wird der Betrachtungsrahmen Θ , in Abhängigkeit der gegebenen Menge, partitioniert. Die Summe der einzelnen A-priori-Wahrscheinlichkeiten ergibt die A-priori-Wahrscheinlichkeit der Partition [Jøs97]. Eine *Event-Instance* gibt somit für jede Situation, die aus einer Menge von Ereignissen besteht, eine *Binomial-Opinion* zurück.

Ein *Condition-Evaluator* kann dadurch die Operatoren der Subjektiven-Logik verwenden und – mit diesen – die Bedingung gemäß der Subjektiven-Logik auswerten. Eine *Binomial-Opinion* beschreibt durch die beiden Werte b und d weiterhin ein Glaubensintervall, weshalb ein

entsprechender *Condition-Evaluator* die Bedingungen nach der Dempster-Shafer-Theorie auswerten kann. Ebenso kann man aus einer *Binomial-Opinion* einen Wahrscheinlichkeitswert bestimmen und dadurch den bisherigen binären *Condition-Evaluator* weiterverwenden bzw. einen neuen für die probabilistische Logik entwickeln. Man erhält somit ein hohes Maß an Flexibilität bezüglich des Einsatzes möglicher *Condition-Evaluators*.

Die beschriebene Umsetzung verwendet sowohl die Subjektive-Logik als auch die Glaubenszuweisungen der Dempster-Shafer-Theorie. Die Glaubenszuweisungen werden hierbei als Eingabe verwendet. Durch sie lässt sich Unsicherheit wie gewünscht, ohne Einschränkung der Kontext-Managementsysteme, darstellen. Die Verteilung des Bayes'schen Netzwerks wird, genau wie die Transitionsbedingungen, über die Subjektive-Logik ausgewertet. Dazu werden die Glaubenszuweisungen, wie beschrieben, auf *Binomial-Opinions* abgebildet. Somit sind alle Anforderungen aus Kapitel 3.2 auf Seite 21 erfüllt.

Durch die Einführung der Glaubenszuweisungen und der *Binomial-Opinions* ändert sich die Definition 1 auf Seite 12 der *Event-Instance*. Die neue Definition lautet wie folgt:

Definition 17 (Event-Instance):

Sei E die Menge aller möglichen Ereignisse eines Ereignistyps und 2^E die Potenzmenge dieser Menge. Die *Event-Instance* $I_E : 2^E \mapsto \omega$ definiert dann eine Abbildung, die jeder Teilmenge des Ereignistyps eine *Binomial-Opinion* ω zuordnet.

Da sich eine Bayes'sche Wahrscheinlichkeitsverteilung durch eine Glaubenszuweisung darstellen lässt und die Subjektive-Logik einen Wahrscheinlichkeitswert für eine *Opinion* definiert, kann Definition 17 als Verallgemeinerung von Definition 1 angesehen werden.

Die beschriebene Erweiterung wird im Folgenden, zur Abgrenzung vom ursprünglichen FlowCon, als Hyper-FlowCon bezeichnet. Abbildung 4.1 zeigt den neuen Aufbau von Hyper-FlowCon (vgl. Abbildung 2.2 auf Seite 15).

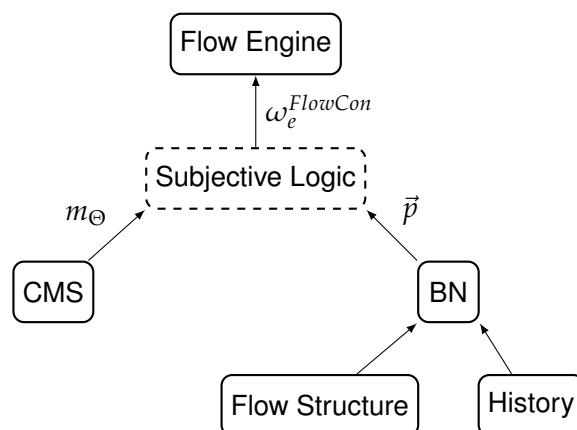


Abbildung 4.1: Aufbau von Hyper-FlowCon

Hyper-Opinions

Es zeigt sich, dass diese neue Definition einer *Event-Instance* in etwa einer *Hyper-Opinion* aus A. Jøsang [Jøs11] entspricht. Dies ist eine Erweiterung der Dempster-Shafer-Theorie. Der grundsätzliche Unterschied ist die Definition der zugrundeliegenden Glaubenszuweisung. Die Glaubenszuweisung einer *Hyper-Opinion* ist, im Gegensatz zu einer Glaubenszuweisung der Dempster-Shafer-Theorie, auf einer reduzierten Potenzmenge $\mathcal{R}(\Theta)$ des Betrachtungsrahmens definiert. Eine solche enthält alle nicht leeren und echten Teilmengen des Betrachtungsrahmens Θ . Dieser Unterschied spielt aber im Falle von Hyper-FlowCon keine Rolle, da es keine Auswertung des kompletten Betrachtungsrahmens gibt. Die Ereignis-Knoten der Transitionsbedingung beziehen sich immer nur auf echte Teilmengen des Ereignistyps, der dem Betrachtungsrahmen entspricht.

Alle projizierten Wahrscheinlichkeitswerte einer *Hyper-Opinions* ergeben summiert zusammen mehr als eins. Eine *Hyper-Opinion* entspricht folglich einer überadditiven Dirichlet-Verteilung.

$$\sum_{x \in \Theta} \vec{E}(x) \geq 1 \quad (4.1)$$

Diese Überadditivität entsteht durch Wertzuweisungen an zweielementige Einträge einer Glaubenszuweisungen. Nach A. Jøsang [Jøs11] entsprechen diese mehrelementigen Einträge nicht der Unsicherheit des Betrachters, sondern dessen Konfusion. Hyper-FlowCon wertet somit, neben der Unsicherheit, auch noch die Konfusion des Betrachters aus.

4.1.3 Änderungen an FlowCon

Um die neue Definition der *Event-Instance* in FlowCon umzusetzen, mussten einige Datentypen neu erstellt bzw. angepasst werden. Die meisten Änderungen wurden am *Event-Instance*-Datentyp durchgeführt. Dieser wies in seiner ursprünglichen Fassung nur Platz für eine einzige probabilistische Wahrscheinlichkeitsverteilung auf, die jedem Element des Ereignistyps zuordnete. Der Ereignistyp entspricht in etwa dem Betrachtungsrahmen der Subjektiven-Logik bzw. der Dempster-Shafer-Theorie.

Da die neue Version eine Glaubenszuweisung und eine separate Verteilung für die A-priori-Wahrscheinlichkeiten des Bayes'schen Netzes benötigt, musste das Interface der *Event-Instance* sowie alle darauf zugreifenden Klassen vollständig überarbeitet werden. Zur Bestimmung der A-priori-Wahrscheinlichkeiten verwendet FlowCon sogenannte *UncertainEventProcessors*, die zu jeder *Event-Instance* eine entsprechende Wahrscheinlichkeitsverteilung bestimmen. Ursprünglich wurden die Wahrscheinlichkeiten direkt mit den Wahrscheinlichkeiten des Kontext-Managementsystems gemittelt und benötigten daher keinerlei weiterer Zuordnung zum Ereignistyp. Für die neue Version mussten daher die *UncertainEventProcessors*, welche die A-priori-Wahrscheinlichkeit aus den Daten des Bayes'schen Netzes berechnen, ebenfalls angepasst werden.

Neben diesen Änderungen wurden noch weitere Anpassungen am Monitoring und an den Lernfunktionen unternommen, um ein anschließendes Auswerten der Ergebnisse zu ermöglichen.

4.2 Verschiedene Eingabe-Verarbeitungen

Hyper-FlowCon erwartet als Eingabe eine Glaubenszuweisung entsprechend der Dempster-Shafer-Theorie. Eine solche kann direkt ohne weitere Umformung von Hyper-FlowCon verarbeitet werden. Leider liefern die wenigsten Kontext-Managementsysteme eine solche Glaubenszuweisung. Die meisten Angaben können aber in eine Glaubenszuweisung überführt werden.

Der folgende Abschnitt 4.2.1 zeigt die Überführung einer Wahrscheinlichkeitsverteilung, wie sie vom ursprünglichen FlowCon verwendet wird, in eine geeignete Glaubenszuweisung. Der anschließende Abschnitt 4.2.2 überträgt dieses Vorgehen auf Kontextinformationen, die nur aus einem einzigen Ereignis bestehen.

4.2.1 Bayes'sche Wahrscheinlichkeitsverteilung

Eine Bayes'sche Wahrscheinlichkeitsverteilung, die auch vom ursprünglichen FlowCon verwendet wurde, kann nach [Bar81; Lv91] direkt, ohne große Probleme, in eine Glaubenszuweisung überführt werden. Die entstehende Glaubenszuweisung weist dann jedoch keinerlei Unsicherheit im Sinne der Subjektiven-Logik auf.

Diese Unsicherheit ist für Hyper-FlowCon sehr wichtig. Ohne sie enthalten die Glaubensintervalle nur einen einzigen Wert, der dem ursprünglichen Wahrscheinlichkeitswert entspricht. Die resultierenden *Binomial-Opinions* wären alle dogmatisch, was zur Folge hätte, dass das Bayes'sche Netz außer Kraft gesetzt wird. Der Grund hierfür ist, dass eine Wahrscheinlichkeitsverteilung additiv ist. Sie wurde so normiert, dass die Summe aller Wahrscheinlichkeiten zusammen den Wert eins ergibt.

In einem solchen Fall ist die Subjektive-Logik identisch mit der probabilistischen Wahrscheinlichkeitstheorie [Jøs10]. Es entsteht kein Nutzen für Hyper-FlowCon. Vielmehr könnte keine Information des Bayes'schen Netzwerkes verwendet werden. Diese würde eine Verschlechterung im Vergleich zum ursprünglichen FlowCon bedeuten.

Aus diesem Grund muss die Unsicherheit der Verteilung Q^{CMS} bestimmt werden. In einer Bayes'schen Wahrscheinlichkeitsverteilung zeichnet sich Unsicherheit durch eine gleichmäßige und ebene Verteilung der Werte aus. Diese sind alle nahe an der Grundwahrscheinlichkeit $\frac{1}{k}$ und weisen somit keine Signifikanz auf. Die Wahrscheinlichkeitsverteilung weist deshalb ebenfalls keine Signifikanz auf, da keiner der Werte signifikant ist bzw. von seiner

zugehörigen Grundwahrscheinlichkeit abweicht. Verteilungen mit einer hohen Signifikanz hingegen enthalten einen Wert, der stark von der Grundwahrscheinlichkeit abweicht. Es ist davon auszugehen, dass das zugehörige Ereignis bzw. die hervorstechende Schlussfolgerung in einem solchen Fall deutlich erkannt wurde und die Verteilung somit eine hohe Sicherheit aufweist. Die Unsicherheit u verhält sich folglich umgekehrt proportional zur Signifikanz. Aus dieser Erkenntnis heraus wird in Hyper-FlowCon die Unsicherheit der Wahrscheinlichkeitsverteilung Q^{CMS} anhand der Signifikanz bestimmt.

Normalerweise wird die Signifikanz einer Verteilung durch die Differenz des kleinsten und des größten Wertes der Verteilung bestimmt. Bei einer Gleichverteilung ist die Differenz aber null und die Unsicherheit somit maximal. Im Falle von Hyper-FlowCon ist es aber sinnvoll, dass die Verteilung Q^{CMS} des Kontextmanagementsystems immer zu einem gewissen Teil in die Auswertung einer *Event-Instance* mit einbezogen wird. Deshalb wird, statt der Differenz, direkt der größte Wahrscheinlichkeitswert \hat{p} als Signifikanz verwendet. Hierdurch ist sichergestellt, dass die Signifikanz nie null beträgt. Die Unsicherheit u ist somit definiert als $u = 1 - \hat{p}$.

Alle Werte der Verteilung Q^{CMS} werden bei der Überführung in eine Glaubenszuweisung entsprechend der Unsicherheit skaliert. Dabei werden diese mit dem größten Wahrscheinlichkeitswert \hat{p} der Verteilung Q^{CMS} multipliziert und übernommen. Die übrige, nicht zugewiesene Wahrscheinlichkeit entspricht der Unsicherheit u . Sie wird der Menge aller möglichen Ereignisse (Θ) zugeordnet. Das Resultat ist eine korrekte Glaubenszuweisung, welche das geforderte Maß an Unsicherheit enthält. Sie kann somit von Hyper-FlowCon sinnvoll eingesetzt werden.

4.2.2 Einzelnes Ereignis

Eine Eingabe, die nur aus einem einzelnen Ereignis besteht, scheint auf den ersten Blick kompliziert, da das Kontext-Managementsystem nur eine Einschätzung für dieses eine Ereignis liefert aber keine Informationen über die restlichen Möglichkeiten. Mit einer probabilistischen Wahrscheinlichkeitsverteilung ist dies, wie das Ellsberg-Paradoxon gezeigt hat, nicht darstellbar. Die Dempster-Shafer-Theorie erlaubt es aber, genau diesen Fall sauber in Form einer Glaubenszuweisung zu beschreiben, indem einer Mengen von Ereignissen ein Wert zugewiesen wird.

Das vom Kontext-Managementsystem ermittelte Ereignis bekommt die zugehörige Wahrscheinlichkeit zugewiesen. Die restliche Wahrscheinlichkeit beträgt folglich $1 - p(e)$. Sie wird dem Komplement $\Theta \setminus e$ des Ereignisses zugeordnet.

Es kommt jedoch auch in diesem Fall zu dogmatischen *Opinions*. Eine solche dogmatische *Opinion* tritt ein, wenn die *Binomial-Opinion* für das vom Kontextmanagementsystem gegebene Ereignis e bestimmt wird. In der Praxis kann einem Kontext-Managementsystem kein hundertprozentiges Vertrauen geschenkt werden. Aufgrund dessen werden alle Werte der

Glaubenszuweisung entsprechend der Signifikanz skaliert. Dabei wird diese – wie zuvor – über die Wahrscheinlichkeit des einzigen und folglich auch größten Ereignisses bestimmt.

Diese Eingabeform wird im Folgenden auch als reduzierte Eingabe bezeichnet. Da sie im Vergleich zur – zuvor beschriebenen – Bayes'schen Wahrscheinlichkeitsverteilung einen stark reduzierten Informationsgehalt aufweist.

Liefert das Kontext-Managementsystem keine Wahrscheinlichkeit zum detektierten Ereignis, kann ersatzweise auch die Zuverlässigkeit des Kontext-Managementsystems verwendet werden. Ein solches System, das beispielsweise mindestens jedes vierte Ereignis richtig erkennt, hat eine Zuverlässigkeit von 25 %. Über die restlichen 75 % sind keine Informationen vorhanden. Diese entsprechen somit der Unsicherheit. Folglich wird diese Wahrscheinlichkeit der Menge Θ zugewiesen.

Durch eine Glaubenszuweisung ist es daher prinzipiell möglich, jedes gängige Kontext-Managementsystem einzusetzen. Das Ergebnis hängt logischerweise davon ab, wie korrekt das Kontext-Managementsystem arbeitet und wie gut Hyper-FlowCon mithilfe der Subjektiven-Logik die Unsicherheit ausgleichen kann.

4.3 Verschiedene Condition-Evaluators

Aufgrund der Neudefinition der *Event-Instance* sind viele verschiedene *Condition-Evaluators* denkbar.

Die *Binomial-Opinion*, die von der *Event-Instance* als Ergebnis einer Anfrage zurückgegeben wird, kann auf einen klassischen Wahrscheinlichkeitswert abgebildet werden. Es ist daher möglich den *Binary-Condition-Evaluator* des ursprünglichen FlowCons weiterzuverwenden. Er wird im Folgenden als BINCE bezeichnet.

Ebenso lassen sich die Transitionsbedingung und die dazugehörigen *Binomial-Opinions* mithilfe der Operatoren der Subjektiven-Logik auswerten. Alternativ kann man die Vier-Wertige-Logik verwenden und die *Event-Instance* zusätzlich auf Widersprüchlichkeit prüfen.

Hyper-FlowCon verwendet, ebenso wie FlowCon, ein *Visitor-Pattern* zum Einbinden von *Condition-Evaluators*. In dieser Diplomarbeit wurden daher einige *Condition-Evaluators* implementiert und getestet. Die Funktionsweise der Wichtigsten wird in den folgenden Abschnitten kurz erklärt.

Es handelt sich um den zuvor erwähnten BINCE, den SUBCE der die Subjektiven-Logik Operatoren zur Auswertung einer Transitionsbedingung verwendet, und den FOURCE, der auf der Vier-Wertigen-Logik basiert.

4.3.1 Binary-Condition-Evaluator

Der BINCE verwendet primär – wie der Name schon andeutet – die Binär-Logik. Er vergleicht den Wahrscheinlichkeitswert der *Binomial-Opinion* mit dem Navigationsschwellwert und gibt entsprechend *Wahr* oder *Falsch* für den zugehörigen Ereignis-Knoten zurück. Die restlichen Operatoren der Transitionsbedingung entsprechen den Binär-Logik-Operatoren.

Dieser *Condition-Evaluator* ist relativ einfach und entspricht, bis auf die Tatsache, dass die Wahrscheinlichkeit über eine Subjektive-Logik *Binomial-Opinion* bestimmt wird, dem ursprünglichen *Condition-Evaluator* aus FlowCon. Er dient primär dem besseren Vergleich der Ergebnisse und der Abschätzung, wie sich die *Binomial-Opinions* der Subjektiven-Logik verhalten.

4.3.2 Subjective-Condition-Evaluator

Der Subjective-Condition-Evaluator oder kurz SUBCE verwendet, im Gegensatz zum BINCE, vollständig die Subjektive-Logik. Ein Ereignisknoten besteht, ähnlich wie beim BINCE, aus dem Navigationsschwellwert und einer *Binomial-Opinion*, die von der *Event-Instance* bestimmt wird. Die Beiden werden aber nicht unmittelbar miteinander verglichen. Stattdessen bilden sie eine Ungleichung, die als Eingabe für die anderen Knoten der Transitionsbedingung verwendet wird.

Diese anderen Knoten einer Transitionsbedingung entsprechen den Operatoren bzw. den Verknüpfungen einer Bedingung. Eine Konjunktion bildet folglich aus zwei Ungleichungen eine neue Ungleichung. Dabei werden die beiden *Binomial-Opinions* entsprechend der Gleichung 3.16 konjugiert. Zur Bestimmung des neuen Navigationsschwellwertes werden die beiden Schwellwerte der ursprünglichen Ungleichungen ebenfalls konjugiert. Da es sich bei diesen um probabilistische Wahrscheinlichkeitswerte handelt, werden sie – entsprechend der probabilistischen Wahrscheinlichkeitstheorie – multipliziert. Das Ergebnis ist eine neue Ungleichung, welche die Konjunktion der beiden vorherigen Ungleichungen darstellt. Nach demselben Verfahren werden beim SUBCE die Disjunktion und Negation umgesetzt. Die folgende Gleichung 4.2 veranschaulicht dieses Vorgehen nochmals.

$$(\omega_x \geq t_x) \wedge (\omega_y \geq t_y) \Rightarrow \omega_{x \wedge y} \geq t_{x \wedge y} \quad (4.2)$$

Bei einer Transitionsbedingung wird somit eine Ungleichung zwischen einer *Binomial-Opinion* und einem Wahrscheinlichkeitswert aufgestellt. Zur anschließenden Auswertung der Transitionsbedingung bzw. der resultierenden Ungleichung wird der projizierte Wahrscheinlichkeitswert der *Binomial-Opinion* bestimmt. Der SUBCE vergleicht diesen anschließend mit dem Navigationsschwellwert t und markiert die Transitionsbedingung entsprechend als erfüllt oder nicht erfüllt.

Durch dieses Vorgehen wird die Unsicherheit in die Auswertung miteinbezogen. Die Transitionsbedingung erhält dadurch eine Angabe, wie sicher das zugehörige Ergebnis ist. Ebenfalls wird erst sehr spät die A-priori-Wahrscheinlichkeit mit der vorhandenen Unsicherheit verrechnet. Demzufolge kann ein Ereignisknoten, der eine geringe Unsicherheit aufweist, einen sehr unsicheren Ereignisknoten ausgleichen. Dies macht den SUBCE robuster gegen Störungen als den BINCE. Durch die, in Kapitel 5 beschriebenen, Simulationen wird dies bestätigt. Speziell bei komplexen Transitionsbedingungen ergibt sich ein positiver Effekt, da hier mehrere Ereignisknoten miteinander verknüpft werden.

Unsicherheitsbegrenzung

Damit die Unsicherheit durch die Verknüpfung von vielen unsicheren Ereignisknoten nicht zu groß wird, wurde der Subjective-Condition-Evaluator in einer weiteren Version um eine Unsicherheitsbegrenzung erweitert.

Es zeigt sich allerdings schnell, dass dies – aufgrund der Konjunktion und Disjunktion der Subjektiven-Logik – völlig unnötig ist. Diese beiden Operatoren verstärken die Unsicherheit nicht, sondern reduzieren sie. Beide Operatoren enthalten, wie aus den Gleichungen 3.16 und 3.17 auf Seite 45 zu erkennen ist, eine Comultiplikation. Das Ergebnis einer Comultiplikation wächst sehr schnell an. Durch diese Eigenschaft und die Tatsache, dass $b + d + u = 1$ gilt, wird die Unsicherheit mit jeder Anwendung der beiden Operatoren deutlich verringert. Eine Begrenzung ist daher zwar denkbar, aber nicht notwendig. Aus diesem Grund wurde diese Erweiterung des SUBCE nicht weiter verwendet.

4.3.3 Four-Condition-Evaluator

Der *Four-Condition-Evaluator* (FOURCE) realisiert die Auswertung der Transitionsbedingungen mithilfe der Vier-Wertigen-Logik. Die Werte der Vier-Wertigen-Logik werden für diesen *Condition-Evaluator* als Pro-Contra-Tupel interpretiert. Er wertet, ähnlich zum BINCE, die *Binomial-Opinion* ω_X direkt aus und vergleicht dabei die Wahrscheinlichkeit der *Opinion* mit dem Navigationsschwellwert t . Das Ergebnis bildet den Pro-Teil des Pro-Contra-Tupels.

Der Contra-Teil wird über weitere Anfragen an die *Event-Instance* bestimmt. Bei diesen Anfragen wird geprüft, ob das wahrscheinlichste Ereignis \hat{e} ein Teil der ursprünglichen Anfrage ist. Ist dies nicht der Fall und der Navigationsschwellwert wird trotzdem überschritten, so ist dies ein Widerspruch. Das Ergebnis ist daher der Wert \top . Sollte der Navigationsschwellwert hingegen nicht erfüllt sein, ergibt diese Kombination von Pro und Contra den Tupel für den Wert f , was einem definitiven „Falsch“ entspricht.

Tabelle 4.1 zeigt nochmals, wie die einzelnen Werte der Vier-Wertigen-Logik beim FOURCE bestimmt werden.

$\omega_X \geq t$	$\hat{e} \in X$	Wert der Vier-Wertigen-Logik	
✓	✓	t	Wahr
✓	✗	\top	Widerspruch
✗	✓	\perp	Unwissenheit
✗	✗	f	Falsch

Tabelle 4.1: Bestimmung der Werte der Vier-Wertigen-Logik

Zur Auswertung der weiteren Transitionsbedingung werden die Operatoren der Vier-Wertigen-Logik verwendet. Die Berechnungsvorschriften sind in den Gleichungen 3.7, 3.8 und 3.9 auf Seite 32 in Kapitel 3.4.1 zu finden. Der FOURCE bezieht durch dieses Vorgehen zusätzlich zur Unsicherheit auch noch den Widerspruch in seine Verarbeitung mit ein. Es muss hier des Weiteren noch definiert werden, wie mit den Werten \perp und \top als Ergebnis einer Transitionsbedingung weiter verfahren wird. Die beiden Werte sind bezüglich ihres Wahrheitsgehaltes nicht vergleichbar. Somit kann man entweder beide als „Falsch“ interpretieren oder beide als „Wahr“.

Tests zeigt, dass es im Fall von Hyper-FlowCon sinnvoll ist, sie als *Wahr* zu interpretieren, was einer Aussage: „Im Zweifelsfalle für den Flow“ entspricht. Sollte ein Ereignis falsch ausgewertet werden, so weicht der erkannte *Flow* von der Realität ab. Das nächste korrekt erkannte Ereignis verhindert daher in der Regel eine weitere Ausführung des falschen *Flows*. Tabelle 4.2 auf der nächsten Seite zeigt die Werte der Vier-Wertigen-Logik und ihre Bedeutung für die Erfüllung einer Transitionsbedingung. Die Abbildung 4.2 zeigt das Bilattice der Vier-Wertigen-Logik mit der aus der definierten Belegung resultierenden Wahrheitsgrenze.




Abbildung 4.2: Designierte Werte des Four-Condition-Evaluators

Wert der Vier-Wertigen-Logik	Ergebnis der Transitionsbedingung
t	Wahr bzw. erfüllt
\top	Wahr bzw. erfüllt
\perp	Wahr bzw. erfüllt
f	Falsch bzw. nicht erfüllt

Tabelle 4.2: Interpretation der Vier-Wertigen-Logik für die Transitionsbedingungen

4.4 Zusammenfassung

Durch die oben beschriebenen Erweiterungen von FlowCon ist es Hyper-FlowCon möglich, die vorhandene Unsicherheit anhand der Signifikanz zu bestimmen und entsprechend der verschiedenen *Condition-Evaluators* zu verarbeiten. Diese können, je nach Implementierung, die Unsicherheiten der Ereignisse miteinander verrechnen oder die Situation auf Widersprüche überprüfen.

Neben diesen Eigenschaften ist es Hyper-FlowCon möglich, eine Glaubenszuweisung als Eingabe zu verarbeiten. Dadurch kann jede Angabe eines Kontext-Managementsystems verarbeitet werden, die in eine Glaubenszuweisung überführt werden kann. Implementiert sind die Verarbeitung einer probabilistischen Wahrscheinlichkeitsverteilung und die Angabe eines einzelnen Ereignisses.

Die Verarbeitung der Glaubenszuweisung und der Verteilung des Bayes'schen Netzwerks entspricht der Subjektiven-Logik. Die dadurch entstehenden *Opinions* lassen sich, wie in Kapitel 3.5 gezeigt wurde, in Dirichlet-Dichtefunktionen überführen. Diese entsprechen Wahrscheinlichkeiten zweiter Ordnung [Jø810]. Hyper-FlowCon bestimmt somit für eine *Event-Instance* die wahrscheinlichste Verteilung, die aus den vorhandenen Informationen möglich ist. Hierzu werden Glauben, Zweifel, Unsicherheit, Vorwissen und Konfusion ausgewertet, weshalb ausgesprochen positive Ergebnisse zu erwarten sind.

Es sei hier noch erwähnt, dass mithilfe der Subjektiven-Logik auch erklären werden kann, warum das ursprüngliche FlowCon in einigen Fällen erstaunlich gut funktioniert. FlowCon geht durch die Mittelung der beiden Quellen Q^{CMS} und Q^{BN} im Sinne der Subjektiven-Logik von einer festen Unsicherheit von 50 % aus. Es benötigt aber, da keine Glaubenszuweisung als Eingabe verwendet wird, immer eine vollständige, probabilistische Wahrscheinlichkeitsverteilung.

Die folgende Tabelle 4.3 auf der nächsten Seite fasst alle wichtigen Änderungen und Erweiterungen von Hyper-FlowCon noch einmal zusammen.

Typ	Name	Funktion
Eingabe	Glaubensfunktion ^a	Präzise Information über Unsicherheit möglich. Intern verwendete Darstellung der Eingabedaten.
Eingabe	Wahrscheinlichkeitsverteilung	Klassisches Ergebnis eines Bayes'schen Klassifikators.
Eingabe	reduzierte Eingabe	Ermöglicht die Auswertung von einzelnen Ereignisangaben.
<i>Event-Instance</i>	Subjektive-Logik	Interne Verarbeitung des Bayes'schen Netzes, entspricht der Subjektiven Logik und somit den Dirichlet-Dichtefunktionen.
<i>Condition-Evaluator</i>	SUBCE	Verwendet Subjektive-Logik zur Auswertung der Ereignis-Knoten.
<i>Condition-Evaluator</i>	FOURCE	Verwendet Vier-Wertige-Logik zur Auswertung der Ereignis-Knoten.

Tabelle 4.3: Zusammenfassung der Änderungen an FlowCon

^aDempster-Shafer-Theorie

5 Simulation und Auswertung

5.1 Aufbau

Die Leistungsfähigkeit von FlowCon und somit auch Hyper-FlowCon wird anhand der *Flow*-Erkennungsrate gemessen. Bei diesem Wert handelt es sich um das Verhältnis zwischen der Anzahl vollständig erkannter und der Anzahl nicht vollständig erkannter *Flows* bzw. Instanzen eines *Flows*. Um die Erkennungsrate zu messen, steht ein Lastgenerator zur Verfügung. Dieser erzeugt ein *Flow*-Modell mit einer realitätsnahen Struktur und eine dazu passende Ereignisfolge [WPH11]. Um dies zu ermöglichen verwendet der Lastgenerator *Flow-Patterns* aus J. M. Lau u. a. [Lau+09]. Das erzeugte Modell und die Ereignisse hängen dabei von einer gegebenen Zahl ab, die als *Seed* bezeichnet wird. Dadurch kann ein generiertes *Flow*-Modell wiederholt für verschiedene Einstellungen getestet werden, da es möglich ist den selben *Seed* mehrfach zu verwenden.

Die vom Lastgenerator erzeugten Ereignisse sind korrekt und eindeutig. Sie weisen also eine Wahrscheinlichkeit von 100 % auf. Zum Bestimmen der Robustheit und Erkennungsrate von Hyper-FlowCon sind sie deshalb ohne Modifikation ungeeignet und müssen erst verschlechtert werden. Zur Verschlechterung kommt dasselbe Verfahren zum Einsatz wie bei den bisherigen FlowCon-Simulationen aus [WHR10; WPH11]. Die Ereignisse werden bei diesem Verfahren vor ihrer Verarbeitung in Abhängigkeit zweier Parameter verfälscht. Der erste Parameter wird als *Ground-Truth* (GT) oder Grundwahrheit bezeichnet. Er gibt an, auf welchen Wert die Wahrscheinlichkeit des Ereignisses gesenkt wird. Die restliche Wahrscheinlichkeit wird anschließend mithilfe einer Bernulli-Verteilung auf die anderen Ereignisse des Ereignistyps entsprechend verteilt. Zusätzlich wird diese Verteilung noch mit einem Rauschen überlagert und normiert. Die Stärke dieses Rauschens entspricht dem zweiten Parameter, der Varianz (V).

Hyper-FlowCon kann drei verschiedene Eingaben verarbeiten. Eine Glaubenszuweisung der Dempster-Shafer-Theorie, eine klassische Wahrscheinlichkeitsverteilung und eine Eingabe in Form eines einzelnen Ereignisses. Speziell die letzte Eingabeform ist sehr interessant. Das übergebene Ereignis kann aufgrund von Rauschen und Fehl-Erkennung nicht mehr das korrekte Ereignis sein. Um dieses einzelne Ereignis zu verarbeiten, muss Hyper-FlowCon der restlichen Menge von möglichen Ereignissen einen gemeinsamen Wahrscheinlichkeitswert zuweisen, was erst durch die Verwendung von Glaubenszuweisungen der Dempster-Shafer-Theorie möglich ist. Wie gut sich eine solche Glaubenszuweisung als Eingabeform eignet,

wird sich daher an diesem Fall zeigen. Deshalb wurde, neben der zuletzt beschriebenen Eingabeform, nur noch eine klassische Wahrscheinlichkeitsverteilung getestet.

Ein Versuch in dieser Ausarbeitung testet eine Kombination aus *Condition-Evaluator* und Eingabeform. Er besteht aus vielen Einzel-Simulationen. Diese stellen jeweils eine Ausführung eines *Flow*-Modells dar, das in Abhängigkeit des getesteten *Seeds* bestimmt wurde. Bei einer solchen Simulation werden jedesmal 200 verschiedene Instanzen eines *Flows* simuliert. Jede dieser *Flow*-Instanz entspricht einer Folge von Ereignissen, die zu einer korrekten Ausführung auf dem zugrunde liegenden *Flow*-Modell führt. Diese Ereignisse werden, wie zuvor erklärt, anhand der genannten Parameter Grundwahrheit und Varianz verfälscht, und anschließend als Eingabe an Hyper-FlowCon übergeben.

Zu Beginn jeder Simulation ist das Bayes'sche Netzwerk in Hyper-FlowCon völlig untrainiert. Daher liefert es erst im Laufe einer Simulation brauchbare Informationen.

Bei jedem Versuch werden für verschiedene Werte der Varianz und Grundwahrheit, jeweils 200 bis 400 verschiedene generierte *Flow*-Modelle getestet. Die Grundwahrheit durchlief dabei Werte von 60 % bis 40 % in 5 % Schritten, die Varianz die Werte 25 %, 40 %, 50 %, 60 %, 66 % und 75 %. Insgesamt ergibt dies 1,2 Millionen bis 2,4 Millionen *Flow*-Instanzen pro Versuch. Damit ist eine ausreichende statistische Relevanz gewährleistet.

Für die Auswertung wurden verschiedene Werte aufgezeichnet. Primär handelte es sich dabei um die, durch die *Event-Instance* bestimmten, *Binomial-Opinions*. Hier kam die Wahrscheinlichkeitsdarstellung zum Einsatz. Von jeder *Binomial-Opinion* wurden der projizierte Erwartungswert $E(x)$, die Sicherheit $c = 1 - u$ sowie die A-priori-Wahrscheinlichkeit aufgezeichnet. Der projizierte Erwartungswert $E(x)$ entspricht der von Hyper-FlowCon bestimmten Wahrscheinlichkeit für die am Ereignisknoten geprüfte Aktivität. Die A-priori-Wahrscheinlichkeit entspricht der durch das Bayes'sche Netz bestimmten Wahrscheinlichkeit. Die Sicherheit c der Eingabe wird verwendet um zu überprüfen, welche Auswirkung diese auf die Auswertung der Transitionsbedingungen hat. Im Falle des SUBCE wurden deshalb zusätzlich der Navigationsschwellwert und die *Binomial-Opinions*, die als Endergebnis einer Transitionsbedingung ausgewertet wurden, aufgezeichnet. Bei den zuletzt genannten *Opinions* wurden ebenfalls der projizierte Erwartungswert $E(x)$, die Sicherheit c und die A-priori-Wahrscheinlichkeit aufgezeichnet. Dadurch ist es möglich, die Sicherheit der Eingabe mit der Sicherheit des Transitionsendergebnisses zu vergleichen und gegenüberzustellen.

Ebenso fand eine Zählung der fälschlicherweise als *Wahr* markierten Ereignis-Knoten statt. Sie entspricht der Fehl-Erkennungsrate und dient zur Abschätzung, wie korrekt die *Flow*-Erkennung von Hyper-FlowCon ist.

5.2 Versuchsübersicht

Die Ergebnisse dieser Arbeit sind in drei Versuchsreihen entstanden. Die erste Versuchsreihe diente zum Kennenlernen der neuen Eigenschaften von Hyper-FlowCon. In dieser Versuchsreihe zeigte sich leider ein deutlicher Einbruch der Erkennungsrate bei geringer Grundwahrheit und starkem Rauschen. Dieser Einbruch wird in Abschnitt 5.3.2 ausführlicher behandelt. Nach einer Analyse wurde Hyper-FlowCon modifiziert und um einen neuen Parameter erweitert. Er beschreibt, wie weit Hyper-FlowCon dem Kontext-Managementsystem vertrauen soll. Diese Änderung wurde in der zweiten Versuchsreihe getestet. In der dritten und letzten Versuchsreihe wurde statt eines fixen Navigationsschwellwerts für die Transitionsbedingung ein adaptiver Ansatz gewählt. Dieser neue Ansatz sollte nochmals eine Verbesserung der Erkennungsrate erzielen.

Tabelle 5.1 zeigt die durchgeführten Versuchsreihen. Die Spalten Eingabeform und *Condition-Evaluator* geben zusammen den durchgeführten Versuch an. Die Spalte Vertrauen gibt den getesteten Wert für den – in der zweiten Versuchsreihe neu eingeführten – Wert des Vertrauens an. In der ersten Versuchsreihe entsprach dieser Wert einem 100 %-igen Vertrauen in das Kontext-Managementsystem. Die Spalte Navigationsschwellwert gibt an, welcher Ansatz zur Bestimmung des Navigationsschwellwerts verwendet wurde.

Eingabe	Vertrauen	Nav.-Schwell.	BinCE	SubCE	FourCE
Einzelnes Ereignis	100 %	Fix		✓	
Wahrscheinlichkeitsverteilung	100 %	Fix	✓	✓	✓
Einzelnes Ereignis	68 %	Fix			
Wahrscheinlichkeitsverteilung	68 %	Fix	✓	✓	
Einzelnes Ereignis	60 %	Fix			
Wahrscheinlichkeitsverteilung	60 %	Fix	✓	✓	
Einzelnes Ereignis	60 %	Adaptiv		✓	
Wahrscheinlichkeitsverteilung	60 %	Adaptiv		✓	✓

Tabelle 5.1: Übersicht der durchgeführten Versuche und Ergebnisse

5.3 Auswertung der Ergebnisse

5.3.1 Referenz

Abbildung 5.1 zeigt das Ergebnis eines Versuchs ohne die Unterstützung von FlowCon oder Hyper-FlowCon. Der 3D-Plot hat als x- und y-Achse die Parameter Varianz und Grundwahrheit. Die Markierungen an den Achsen entsprechen den simulierten Werten für die beiden Parameter. Die z-Achse entspricht der Prozentzahl an vollständig durchgeführten bzw. erkannten *Flows* und wird im Weiteren als Erkennungsrate bezeichnet. Zum besseren Vergleich wird das Höhenprofil bei allen Ergebnissen der Erkennungsrate gleich eingefärbt. Ebenso sind Höhen- und Konturlinien für wichtige Werte in das Schaubild eingezeichnet.

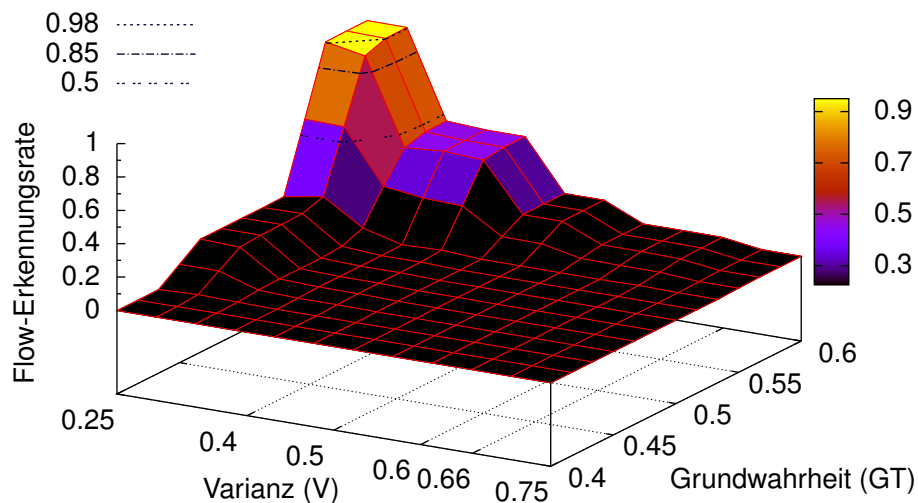


Abbildung 5.1: Erkennungsrate ohne die Unterstützung von FlowCon oder Hyper-FlowCon

Es ist deutlich zu erkennen, dass nur bis zu einer Grundwahrheit von 60 % ohne nennenswertes Rauschen (Varianz von 25 %) ein akzeptables Ergebnis geliefert wird. Eine Erkennungsrate von über 92 % ist – per se – wenig überraschend, da das korrekte Ereignis in diesem Bereich immer einen Wert von etwa 60 % auf weißt. Die restliche Wahrscheinlichkeit ist, mithilfe der Bernulli-Verteilung, über die anderen Ereignisse verteilt. Diese stellen deshalb keine echte Konkurrenz dar.

Hyper-FlowCon ist eine Erweiterung von FlowCon. Die Ergebnisse werden deshalb nicht mit dem obigen Ergebnis verglichen, sondern mit den Ergebnissen von FlowCon. Daher wurde ein weiterer Versuch für das gleiche Szenario mit dem ursprünglichen FlowCon durchgeführt. Das Ergebnis dieses Versuchs ist, ebenfalls als 3D-Plot, in Abbildung 5.2 zu sehen.




Abbildung 5.2: Erkennungsrate von FlowCon

In Tabelle 5.2 sind die Messwerte des Höhenprofils aus Abbildung 5.2 dargestellt. Die Felder entsprechen der Prozentzahl der erkannten *Flows*, die Spalten der Varianz und die Zeilen der Grundwahrheit.

Grundwahrheit	Erkennungsrate (%) bei Varianz					
	25 %	40 %	50 %	60 %	66 %	75 %
60%	86	83	81	79	78	76
55%	82	79	78	76	75	73
50%	78	75	74	72	71	69
45%	73	69	67	65	64	61
40%	58	56	56	56	56	54

Tabelle 5.2: Erkennungsrate von FlowCon

FlowCon bringt in diesem Fall eine überaus deutliche Verbesserung. Wo zuvor keine einzige *Flow*-Instanz vollständig erkannt wurde, werden durch FlowCon mehr als 50 % aller *Flow*-Instanzen erkannt. In den meisten Fällen sogar über 66 %. Es gibt aber auch Verschlechterungen. Bei einer Grundwahrheit von 60 % und einer Varianz von 25 % wird die Erkennungsrate von über 92 % auf knapp 85 % gesenkt. Der Grund hierfür ist die Mittelung der Eingabe-Verteilung mit der Verteilung des Bayes'schen Netzwerks. Dieses ist zu Beginn völlig untrainiert und gibt somit nur eine Gleichverteilung zurück. Das nahezu eindeutige Ergebnis des Kontext-Managementsystems wird dadurch verschlechtert. Ebenso verschlechtert FlowCon Ereignisse, die von der üblichen *Flow*-Instanz statistisch abweichen. Trotz

dieser punktuellen Schwächen liefert FlowCon ein ausgesprochen gutes Ergebnis, welches die Referenz für Hyper-FlowCon und die damit durchgeführten weiteren Versuchsreihen darstellt.

Die Gesamt-Fehl-Erkennungsrate beträgt bei diesem Versuchsergebnis durchschnittlich ca. 9 %. Dieser Wert ist jedoch irrelevant, da er sowohl nicht erkannte als auch falsch erkannte Ereignisse enthält. Nicht erkannte Ereignisse führen zu einem *Flow*-Abbruch und stellen kein Problem dar. Falsch erkannte Ereignisse, also Ereignisse, die in dieser Form nicht stattgefunden haben, können hingegen zu einer falschen Protokollierung der Ereignisse und Aktivitäten des Benutzers führen. Der Prozentsatz an falsch erkannten Ereignissen beträgt für FlowCon 2,0 % mit einer Standardabweichung von gerade einmal 3,8 %. Er stellt die Obergrenze der Fehl-Erkennungsrate dar, da nicht jedes falsch erkannte Ereignis unbemerkt bleibt. Bei einem falschen Aktivitätswechsel z. B. passen die restlichen – korrekt erkannten – Ereignisse nicht mehr zusammen, weshalb der *Flow* abbricht. Eine unbemerkte Falsch-Protokollierung findet in diesem Fall somit nicht statt. Ebenso relativieren die Operatoren der Transitionsbedingungen den Fehl-Erkennungswert. Bei einer Disjunktion \vee mit einem korrekt erkannten, positiven Ereignis $e_1 = 1$ ist der Wert des anderen Ereignisses irrelevant. Es entsteht bei der Binär-Logik in einem solchen Fall immer ein korrektes und positives Ergebnis.

5.3.2 Erster Durchgang

Vollständige Verteilung

Im ersten Versuch wurde Hyper-FlowCon mit dem SUBCE und einer vollständigen Wahrscheinlichkeitsverteilung als Eingabe getestet. Wie aus Abbildung 5.3 hervorgeht, bringt die Subjektive-Logik eine erkennbare Verbesserung. Die Fehl-Erkennungsrate (falsch positiv) lag hier bei ca. 2,7 %, was noch immer sehr gering ist. Eine falsche *Flow*-Ausführung ist bei einem solchen Wert sehr unwahrscheinlich, da in der Regel ein einziges falsches Ereignis zu einem Abbruch des *Flows* führt.

Allerdings ist bei diesem Versuch ein negativer Effekt zu beobachten. Die Ergebnisse in der vorderen rechten Ecke brechen ein. Dieser Bereich entspricht einer geringen Grundwahrscheinlichkeit und einer starken Varianz. Noch deutlicher wird dieser Effekt bei der Verwendung des *Binary-Condition-Evaluator*, dessen Ergebnisse in Abbildung 5.4 zu sehen sind.

Dieser *Condition-Evaluator* wird auch vom ursprünglichen FlowCon verwendet, weshalb die Ursache nicht im *Condition-Evaluator* sondern in der vorgeschalteten Verarbeitung der Eingabe zu suchen ist. Einen entscheidenden Hinweis brachte die Auswertung der Unsicherheit im *Flow* bei der Verwendung des SUBCE. Dabei wurde die Sicherheit¹ der *Binomial-Opinions*,

¹Sicherheit c ist umgekehrt proportional zur Unsicherheit u : $c = 1 - u$




Abbildung 5.3: Erkennungsrate von Hyper-FlowCon mit SUBCE




Abbildung 5.4: Erkennungsrate von Hyper-FlowCon mit BINCE

welche die Endergebnisse der Transitionsbedingungen darstellen, gemittelt und grafisch dargestellt. Die x - und y -Achsen entsprechen auch in dieser Grafik der Varianz und der Grundwahrheit. Die z -Achse hingegen entspricht der mittleren Sicherheit der Transitionen, welche im Folgenden als *Flow-Sicherheit* bezeichnet wird. Um Verwechslungen zu vermeiden sind die Höhenprofile der *Flow-Sicherheit* anders eingefärbt, als die der *Flow-Erkennungsrate*.




Abbildung 5.5: *Flow-Sicherheit* beim SUBCE




Abbildung 5.6: Mittlere Sicherheit der Eingabe bei einer vollständigen Verteilung

Abbildung 5.5 zeigt die *Flow*-Sicherheit von Hyper-FlowCon bei der Verwendung des SUBCE und einer vollständigen Verteilung als Eingabe. Analog dazu ist in Abbildung 5.6 die dazugehörige mittlere Sicherheit der Eingabe dargestellt. Beim Vergleich dieser beiden Schaubilder ist eine deutliche Steigerung der Sicherheit zu erkennen, was einen Rückgang der Unsicherheit bedeutet. Hyper-FlowCon reduziert folglich – durch die Verwendung der Subjektiven-Logik – die Unsicherheit sehr stark. Dadurch wird weniger Information aus dem Bayes'schen Netz verwendet. Dies erhöht prinzipiell die Genauigkeit und führt zu einer korrekteren Erkennung, welche mehr auf Tatsachen als auf Annahmen beruht.

Allerdings entsprechen die Werte des Kontext-Managementsystems bei einer geringen Grundwahrheit und einem starken Rauschen nicht mehr der Realität bzw. dem ursprünglichen Ereignis. Deshalb sollte die *Flow*-Sicherheit bei steigender Varianz und sinkender Grundwahrheit abnehmen. Dies ist jedoch nur bedingt der Fall. Auffällig ist hier nochmals die Position (GT: 0,4, V: 0,75) in der rechten vorderen Ecke der Abbildung 5.5, welche die *Flow*-Sicherheit darstellt. Hier steigt die Sicherheit auf einen ähnlichen Wert wie in der hinteren linken Ecke (GT: 0,6, V: 0,25). *Flows* in diesem hinteren Bereich können aber noch ohne die Verwendung eines Bayes'schen Netzes, und damit ohne FlowCon oder Hyper-FlowCon, verarbeitet werden.

Der Einbruch der Erkennungsrate beruht auf der nicht ganz korrekten Annahme bezüglich der Beziehung zwischen Signifikanz und Sicherheit aus Kapitel 4. Es ist vollkommen richtig, dass eine Verteilung mit einer geringen Signifikanz ein hohes Maß an Unsicherheit aufweist. Der Umkehrschluss ist aber nicht ganz korrekt. Hohe Signifikanz kann neben einer hohen Sicherheit auch als Folge einer starken Varianz auftreten. In einem solchen Fall sticht ein Wert aus der Verteilung heraus. Dieser muss aber nicht unbedingt zur korrekten Schlussfolgerung oder dem korrekten Ereignis gehören. Genau dies tritt bei einer Grundwahrheit von rund 40 % und einer starken Varianz in den durchgeführten Versuchen ein. Dies kann folgendermaßen interpretieren werden: Hyper-FlowCon wird „angelogen“ und nimmt dies „für bare Münze“.

Die von FlowCon verwendete Mittelung liefert an dieser Stelle ein deutlich besseres Resultat. Im Sinne der Subjektiven-Logik entspricht diese Mittelung einer festen Unsicherheit von 50 %. FlowCon geht daher bei jeder Eingabe von einer Unsicherheit von 50 % aus, ohne die Eigenschaften der Verteilung weiter in Betracht zu ziehen. Diese Eigenschaft ist in Bereichen, in denen eine geringe Grundwahrheit und eine starke Varianz auftreten, besser geeignet als die direkte Übernahme der Signifikanz als Sicherheit.

Die Verwendung der Vier-Wertigen-Logik zum Auswerten der Transitionsbedingungen ändert an diesem Problem nichts. Aufgrund der vier diskreten Werte fallen die Ergebnisse, wie in Abbildung 5.7 zu sehen ist, ähnlich zu denen des *Binary-Condition-Evaluators* aus. Allerdings kann der FOURCE durch seine beiden zusätzlichen Werte die Erkennungsrate bei hoher Grundwahrheit deutlich steigern.




Abbildung 5.7: Erkennungsrate von Hyper-FlowCon mit FOURCE

Ein Ereignis als Eingabe

Neben der vollständigen Verteilung wurde auch die Eingabe in Form eines einzelnen Ereignisses getestet. Diese Eingabe enthält deutlich weniger Informationen als eine vollständige Verteilung. In den meisten Fällen bedeutet dies einen Informationsverlust von über 50 %. Es ist daher von einer ebenso deutlichen Verschlechterung auszugehen. Wie in Abbildung 5.8 zu sehen ist, kann die Subjektive-Logik – in Verbindung mit dem SUBCE – diese fehlende Information jedoch ausgleichen.

Es ist – im Vergleich zu einer vollständigen Verteilung als Eingabe (siehe Abbildung 5.3) – nur eine minimale Verschlechterung zu erkennen. Die Subjektive-Logik gleicht die fehlenden Informationen durch eine höhere Unsicherheit aus und verwendet somit im Zweifelsfall mehr Informationen aus dem Bayes'schen Netz. Abbildung 5.9 auf der nächsten Seite zeigt die *Flow*-Sicherheit, die aufgrund der fehlenden Informationen erwartungsgemäß gesunken ist.

Der Prozentsatz an falsch erkannten Ereignissen (falsch positiv) ist in diesem Versuch aufgrund der fehlenden Informationen auf 3,5 % gestiegen. Die Standardabweichung beträgt dabei 5,5 %.

Dieses Ergebnis zeigt, dass die Subjektive-Logik an sich ein geeignetes Unsicherheitsmodell für FlowCon ist. Damit ist es möglich, Eingaben, die aus nur einem einzelnen Ergebnis bestehen, zu verarbeiten. Die Bestimmung der Unsicherheit benötigt allerdings eine Überarbeitung.




Abbildung 5.8: Erkennungsrate des SUBCE bei einer reduzierten Eingabe




Abbildung 5.9: Flow-Sicherheit des SUBCE bei einer reduzierten Eingabe

5.3.3 Begrenztes Vertrauen

Um die in Abschnitt 5.3.2 deutlich aufgetretene Verschlechterung bei einer geringen Grundwahrheit und starkem Rauschen zu beheben, wurde eine Änderung an Hyper-FlowCon vorgenommen. Hyper-FlowCon wird im genannten Bereich sozusagen „angelogen“. Aus menschlicher Sicht wird einer Quelle, die häufiger falsche Informationen bzw. falsche Schlussfolgerungen liefert, ein geringes Vertrauen geschenkt.

Bei Hyper-FlowCon wurde deshalb eine Vertrauensangabe eingebaut. Bis zu dieser Angabe vertraut Hyper-FlowCon dem Kontext-Managementsystem. Übersteigt die Sicherheit den Vertrauenswert, wird Hyper-FlowCon sozusagen „misstrauisch“ und hält an der Unsicherheit, die durch den Vertrauenswert gegeben ist, fest. Die Werte des Kontext-Managementsystems Q^{BN} werden sozusagen mit den Werten des Bayes'schen Netzwerks Q^{CMS} abgeglichen.

Die Unsicherheit bzw. Sicherheit wird weiterhin über die Signifikanz bestimmt. Sollte die Sicherheit jedoch über den durch das Vertrauen festgelegten Wert steigen, wird Unsicherheit hinzu geführt, wodurch Hyper-FlowCon die Ergebnisse des Kontext-Managementsystems teilweise ignoriert. Die *Binomial-Opinions* weisen somit nie eine höhere Sicherheit auf, als von dem neuen Parameter des Vertrauens vorgegeben wird.

Durch diese Begrenzung sinkt die *Flow*-Sicherheit. Dies ist jedoch unkritisch, da Hyper-FlowCon bei der Verwendung des *Subjective-Condition-Evaluators* das Bayes'sche Netz in geringerem Umfang verwendet als das ursprüngliche FlowCon. Dieses nutzt die Informationen Q^{BN} des Bayes'schen Netzwerks generell zu 50 %. Hyper-FlowCon hingegen verwendet mit dem SUBCE im Mittel maximal 40 % dieser Informationen. Deshalb ist es problemlos möglich, dem System zusätzliche Unsicherheit zuzuführen, ohne dabei Gefahr zu laufen, dass ausschließlich mit den Wahrscheinlichkeiten Q^{BN} des Bayes'schen Netzwerks gearbeitet wird.

A. Jøsang erwähnt in seinen Arbeiten [Jøs01; Jøs07; Jøs10] wiederholt, dass Schlussfolgerungen mit einer 100 %-igen Sicherheit in der realen Welt nicht möglich sind. Auch durch diese Aussage wird das hier beschriebene Vorgehen unterstützt.

Um einen geeigneten Wert für den neuen Vertrauensparameter zu bestimmen, wurden mehrere Versuche durchgeführt. Der Parameter wurde dabei Schritt für Schritt verringert, bis ein akzeptables Ergebnis, in Form einer guten *Flow*-Erkennung, eintrat. Der BINCE zeigt von den getesteten *Condition-Evaluatoren* den deutlichsten Einbruch. Der Effekt des „Angelogen-Werdens“ ist bei ihm am deutlichsten ausgeprägt. Als Eingabe kam eine vollständige Verteilung zum Einsatz, um mögliche Nebeneffekte auszuschließen.

Der zuerst gewählte Vertrauenswert betrug 66 %. Er ist jedoch zu hoch, um den Einbruch auszugleichen und bringt nur eine geringfügige Verbesserung. Der nächste Wert wurde deshalb kleiner gewählt und beträgt 60 %. Er kann, wie in Abbildung 5.10 zu erkennen ist, den Einbruch fast vollständig ausgleichen.




Abbildung 5.10: Erkennungsrate des BINCE bei einem Vertrauen von 60%

Bei der Verwendung des SUBCE, dessen Erkennungsrate in Abbildung 5.11 auf der nächsten Seite dargestellt wird, ist kein Einbruch mehr zu erkennen. Eine weitere Reduzierung des Vertrauenswerts fand daher nicht statt. Tabelle 5.3 auf der nächsten Seite stellt die Erkennungsrate für den Vertrauenswert von 60 % nochmals tabellarisch dar. Die Fehl-Erkennungsrate (falsch positiv) ist durch die Einführung des Vertrauenswerts um 0,1 % angestiegen. Sie beträgt beim Versuch aus Abbildung 5.11 2,8 %. Diese geringfügige Erhöhung hält sich, im Vergleich zur gesteigerten Erkennungsrate, in Grenzen. Es muss hier auch in Betracht gezogen werden, dass auch die von Menschen erstellten Protokolle und Aufzeichnungen nicht hundertprozentig fehlerfrei sind.

Der Ansatz vom ursprünglichen FlowCon, mit einem Fixwert von 50 % für die Unsicherheit, funktioniert bei geringer Grundwahrheit und starkem Rauschen sehr gut. Dies liegt daran, dass die Sicherheit proportional zur Grundwahrheit verläuft. Das Vertrauen müsste für geringere Grundwahrheitswerte als 40 % noch weiter gesenkt werden. Dies führt allerdings zu einer nicht gewollten, stärkeren Verwendung des Bayes'schen Netzes und somit zu einer – unter Umständen – weniger akkuraten Erkennung.

Um zu kontrollieren, in welchem Ausmaß die Flow-Sicherheit zurückgegangen ist, wurde eine weitere Auswertung der Flow-Sicherheit bei der Verwendung des SUBCE durchgeführt. Sie ist in Abbildung 5.12 auf Seite 79 dargestellt.




Abbildung 5.11: Erkennungsrate des SUBCE bei einem Vertrauen von 60%

Grundwahrheit	Erkennungsrate (%) bei Varianz					
	25 %	40 %	50 %	60 %	66 %	75 %
60%	94	91	90	87	88	86
55%	89	87	86	85	85	83
50%	84	82	82	81	81	79
45%	79	79	78	76	75	74
40%	74	71	69	67	66	64

Tabelle 5.3: Erkennungsrate des SUBCE bei einem Vertrauen von 60%

Trotz der Einführung eines maximalen Vertrauens und einer daraus resultierenden Begrenzung der maximalen Eingabe-Sicherheit, verwendet Hyper-FlowCon in jedem Fall weniger als 40 % der Informationen des Bayes'schen Netzes.

Von der Einführung des Vertrauensparameters profitiert auch der FOURCE, dessen Ergebnis in Abbildung 5.13 dargestellt ist. Obwohl er mit nur vier verschiedenen Werten arbeitet, zeigt er ähnlich gute Leistungen wie der SUBCE.

Die Begrenzung bringt ebenfalls eine deutliche Verbesserung bei Eingaben, die aus nur einem einzigen Ereignis bestehen. Die Subjektive-Logik kann die fehlenden Informationen problemlos ausgleichen. Die entstandene Flow-Sicherheit liegt, trotz des festgelegten Vertrauens von 60 %, auch bei dieser Eingabeform noch immer über 50 %, was ein sehr gutes Ergebnis darstellt.




Abbildung 5.12: Flow-Sicherheit beim SUBCE mit einem Vertrauen von 60%




Abbildung 5.13: Erkennungsrate des FOURCE bei einem Vertrauen von 60%

5.3.4 Adaptiver Grenzwert

Beim Abstimmen des neuen Vertrauensparameters ist eine Unstimmigkeit des Navigationsschwellwerts aufgefallen. In bestehenden Untersuchungen wurde für FlowCon ein idealer Navigationsschwellwert von 40 % ermittelt [WHR10]. Allerdings wurde dieser Navigationsschwellwert für ein festes Szenario mit einem festen Betrachtungsrahmen bestimmt. Der Lastgenerator von FlowCon hingegen erzeugt Betrachtungsrahmen, die unterschiedliche Größen haben können. So ist z. B. ein Navigationsschwellwert von 40 % für einen zweielementigen Betrachtungsrahmen viel zu niedrig. Für einen Betrachtungsrahmen mit zehn oder mehr Elementen ist er wiederum deutlich zu hoch. Für den allgemeinen Fall müsste er folglich in Relation gesetzt werden zur Größe des Betrachtungsrahmens bzw. des Ereignistyps.

In den folgenden Versuchen wurde die Definition des Navigationsschwellwerts so abgeändert, dass er eine Abhängigkeit von der Größe des Betrachtungsrahmens erhält. Die neue Definition besteht aus der Grundwahrscheinlichkeit eines einzelnen Ereignisses plus einem gewissen Teil der restlichen Wahrscheinlichkeit. Die folgende Gleichung 5.1 zeigt die neue Formel zur Bestimmung des adaptiven Navigationsschwellwerts t_a .

$$t_a = \frac{|x|}{|\Theta|} + s \cdot \left(1 - \frac{|x|}{|\Theta|}\right) \quad \text{mit } x \subseteq \Theta \text{ und } s \in [0 : 1] \quad (5.1)$$

Der neue Navigationsschwellwert prüft somit in gewisser Weise die Signifikanz bzw. den Informationsgehalt. Ein ähnliches Vorgehen wurde von J. Biswas u. a. [Bis+10] vorgestellt und erfolgreich getestet. Dort wurde der Navigationsschwellwert direkt an die Entropie gekoppelt.

Aufgrund der Größe des Betrachtungsrahmens aus [WHR10], der zur Bestimmung des idealen fixen Navigationsschwellwerts verwendet wurde, konnte der ideale Wert, für den in der Gleichung 5.1 neu eingeführten Parameter s auf einen Bereich zwischen 25 % und 30 % eingegrenzt werden².

Zur Überprüfung des neuen Navigationsschwellwerts wurde eine weitere Versuchsreihe gestartet. Die folgenden Versuche verwendeten die Erkenntnisse der vorangegangenen beiden Versuchsreihen. Das Vertrauen betrug weiterhin 60 %. Als *Condition-Evaluator* kam der SUBCE zum Einsatz. Dieser hatte bisher die beste Erkennungsrate erzielt.

Abbildung 5.14 zeigt das Ergebnis für einen Schwellwertparameter s von 25 % und Abbildung 5.15 auf der nächsten Seite das Ergebnis bei einem Schwellwertparameter s von 30 %. Bei beiden ist eine überaus deutliche Verbesserung zu erkennen. Für den Wert s von 25 % konnten – bis zu einer Grundwahrheit von 50 % – über 92 % der *Flow*-Instanzen erkannt werden. Dies stellt eine enorme Verbesserung dar. Abbildung 5.15 zeigt ebenfalls ein positives

²Der Wert des Parametes s wird in diesem Dokument zur Verdeutlichung in Prozent angegeben – es wird aber mit dem dezimalen Wert gerechnet.




Abbildung 5.14: Erkennungsrate des SUBCE mit einem adaptiven Schwellwert s von 25 %




Abbildung 5.15: Erkennungsrate des SUBCE mit einem adaptiven Schwellwert s von 30 %

Ergebnis. Allerdings fällt beim Vergleich der beiden Ergebnisse auf, dass ein Wert von 30 % für den Parameter s zu hoch ist. Die 92 %-Markierung verschiebt sich sehr deutlich nach hinten, was eine schlechtere *Flow*-Erkennungsrate bei geringerer Grundwahrheit bedeutet. In Abbildung 5.14 auf der vorherigen Seite ist hingegen zu erkennen, dass 25 % für den Parameter s zu niedrig gewählt sind. Bei einer Grundwahrscheinlichkeit von 40 % und einer geringen Varianz wird ein nicht ganz so gutes Ergebnis erzielt, wie in den anderen Bereichen. Der ideale Wert muss sich folglich irgendwo zwischen diesen beiden Werten befinden.

5.3.5 Endergebnisse

Für die Endergebnisse der beiden entwickelten *Condition-Evaluators* SUBCE und FOURCE, wird der Schwellwertparameter s auf 28 % gesetzt. Dieser Wert liefert einen guten Kompromiss zwischen den beiden, im vorherigen Abschnitt 5.3.4, beschriebenen Fällen. Das Vertrauen beträgt weiterhin 60 %. Bei den Versuchen mit den beiden *Condition-Evaluators* kommt jeweils eine vollständige Wahrscheinlichkeitsverteilung zum Einsatz. Für den SUBCE wird zusätzlich noch ein Versuch mit einem einzelnen Ereignis als Eingabe durchgeführt.

Die Abbildung 5.16 und Abbildung 5.17 zeigen die Erkennungsrate und die *Flow*-Sicherheit des SUBCE für eine vollständige Verteilung. Beim Vergleich dieser Ergebnisse mit dem Referenz-Ergebnis aus Abbildung 5.2 auf Seite 69 zeigt sich, dass die in Hyper-FlowCon enthaltenen Änderungen eine sehr deutliche Verbesserung erbringen. Auch beim Ergebnis in Abbildung 5.16 werden in über 50 % der Fälle mehr als 92 % der *Flow*-Instanzen erkannt. Die schlechteste *Flow*-Erkennungsrate beträgt – wie in Tabelle 5.4 zu sehen ist – 80 %, was ein extrem gutes Ergebnis darstellt. Im direkten Vergleich zum Referenzsystem handelt es sich um eine relative Verbesserung von fast 50 %. Die Fehl-Erkennungsrate (falsch positiv) ist trotz des geänderten Grenzwertes und der deutlich höheren Erkennungsrate mit 4 % sehr gering. Ob ein falsch erkanntes Ereignis eine Auswirkung auf die *Flow*-Ausführung hat, hängt – wie zuvor erwähnt – vom Aufbau der jeweiligen Transitionsbedingung ab. Daher stellen die angegebenen 4 % eine Obergrenze dar. Die Wahrscheinlichkeit einer völlig falschen *Flow*-Ausführung ist gering.

Tabelle 5.4 zeigt das Endergebnis der Erkennungsrate des SUBCE, mit einem Vertrauen von 60% und einem Wert s von 28 %. Die Werte entsprechen dem Höhenprofil aus Abbildung 5.16.

Die Ergebnisse für den *Four-Condition-Evaluator* sind in Abbildung 5.18 und in Tabelle 5.5 zu finden. Auch dieser bringt eine deutliche Verbesserung im Vergleich zum Referenzsystem. Sie ist zwar nicht so groß wie die des SUBCE, allerdings verwendet der FOURCE auch nur vier diskrete Werte zur Auswertung der Transitionsbedingungen. Sein gutes Ergebnis kann darauf zurückgeführt werden, dass zusätzlich zur Unsicherheit auch der Widerspruch in die Verarbeitung einbezogen wird.

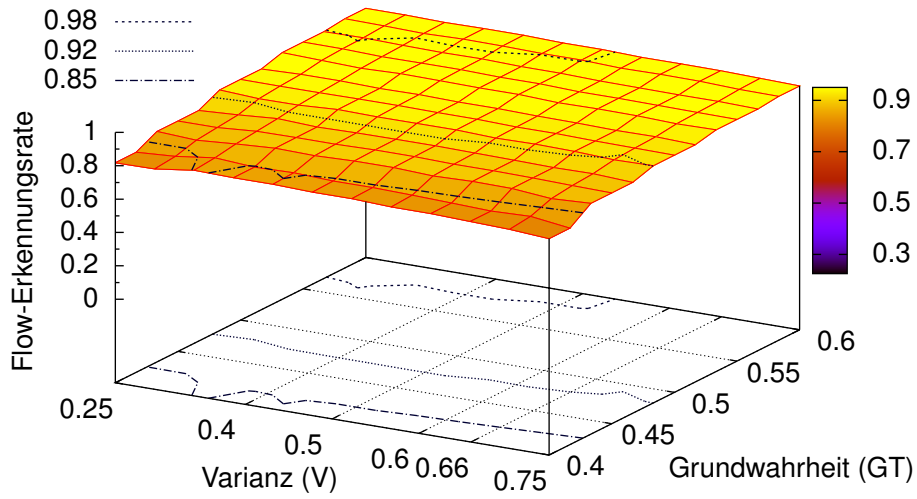


Abbildung 5.16: Erkennungsrate des SUBCE mit $s = 28\%$ und 60% Vertrauen




Abbildung 5.17: Flow-Sicherheit beim SUBCE mit $s = 28\%$ und 60% Vertrauen

Grundwahrheit	Erkennungsrate (%) bei Varianz					
	25 %	40 %	50 %	60 %	66 %	75 %
60%	99	99	98	98	97	96
55%	98	97	96	96	95	95
50%	94	94	94	93	93	92
45%	88	90	90	90	89	88
40%	82	85	84	83	82	80

Tabelle 5.4: Erkennungsrate des SUBCE mit $s = 28\%$ und 60% Vertrauen




Abbildung 5.18: Erkennungsrate des FOURCE mit $s = 28\%$ und 60% Vertrauen

Grundwahrheit	Erkennungsrate (%) bei Varianz					
	25 %	40 %	50 %	60 %	66 %	75 %
60%	98	96	96	94	94	92
55%	95	94	92	91	90	89
50%	89	89	88	87	87	86
45%	85	84	82	81	80	78
40%	76	75	74	72	71	68

Tabelle 5.5: Erkennungsrate des FourCE mit $s = 28\%$ und 60% Vertrauen

Der Wert s von 28 % scheint für den *Four-Condition-Evaluator* etwas zu hoch zu sein. Dieser *Condition-Evaluator* lebt vom Widerspruch, der von einem niedrigen Navigationsschwellwert begünstigt wird. Vermutlich erzielt der FOURCE bei einem niedrigeren Wert s – und damit einem niedrigeren Navigationsschwellwert – ein etwas besseres Ergebnis als das in Abbildung 5.18 auf der vorherigen Seite dargestellte.




Abbildung 5.19: Erkennungsrate des SUBCE, $s = 28\%$, 60 % Vertrauen, reduzierte Eingabe

Grundwahrheit	Erkennungsrate (%) bei Varianz					
	25 %	40 %	50 %	60 %	66 %	75 %
60 %	99	97	95	94	93	92
55 %	96	93	92	91	90	89
50 %	91	89	88	87	86	86
45 %	84	83	83	83	83	81
40 %	70	73	75	76	76	75

Tabelle 5.6: Erkennungsrate des SUBCE, $s = 28\%$, 60 % Vertrauen, reduzierte Eingabe

Abbildung 5.19 zeigt die Erkennungsrate des *Subjective-Condition-Evaluators* für den Fall, dass nur ein einziges Ereignis vom Kontext-Managementsystem zurückgegeben wird. Die 85 %-Marke verläuft entlang der Grundwahrheit von 50 %. Die schlechteste Erkennungsrate beträgt bei diesem Versuch ca. 70 % für eine Grundwahrheit von 40 % und für entsprechendes Rauschen (siehe Tabelle 5.6). Das Referenzsystem bringt ähnliche Werte nur für eine Grundwahrheit von 50 %. Allerdings verwendet dieses eine vollständige Verteilung als Eingabe. Das Ergebnis für des SUBCE bei der Eingabe in Form von einem einzelnen

Ereignis zeigt sehr deutlich, wie gut die Unsicherheit der Eingabe durch die Subjektive-Logik ausgeglichen wird. Auch in diesem Versuch lag die Fehl-Erkennungsrate (falsch positiv) mit 4,6% unter 5%. Eine falsche *Flow*-Ausführung ist deshalb auch hier, trotz der geringeren Informationsmenge, eher unwahrscheinlich.

5.4 Zusammenfassung

Die Änderungen in Hyper-FlowCon brachten eine enorme Verbesserung. In der ersten Versuchsreihe zeigte sich ein Einbruch der Erkennungsrate. Die Einführung eines weiteren Parameters konnte dies jedoch beheben. Der neue Parameter beschreibt, wie weit der Quelle Q^{CMS} , die das Kontext-Managementsystem repräsentiert, vertraut werden kann. Übersteigt die Sicherheit eines Ereignisses diesen Wert, wird bewusst Unsicherheit hinzugefügt, um eine bessere *Flow*-Erkennungsrate zu gewährleisten. Hyper-FlowCon ignoriert somit teilweise die erkannten Informationen. Es wird bei diesem Ansatz davon ausgegangen, dass Ereignisse, die eine hohe Sicherheit aufweisen, durch Störungen entstanden sind und nicht durch eine korrekte Erkennung. Die Werte des Kontext-Managementsystems werden dadurch indirekt mit den Informationen Q^{BN} des Bayes'schen Netz validiert. In der zweiten Versuchsreihe wurde der neue Parameter überprüft und anhand zugewiesener Werte plausibilisiert.

Die Auswertung der *Flow*-Sicherheit zeigte zudem, dass Hyper-FlowCon bei der Verwendung des SUBCE deutlich weniger Informationen aus dem Bayes'schen Netzwerk verwendet als das ursprüngliche FlowCon. Die *Flow*-Sicherheit lag konstant über 50%. Obwohl der neue Vertrauensparameter dem *Flow* zusätzliche Unsicherheit zuführt, lag die *Flow*-Sicherheit im Endergebnis sogar konstant über 60%. Das ursprüngliche FlowCon verwendet, im Vergleich dazu, wegen der Mittelung der Verteilungen immer zu 50% die Informationen aus dem Bayes'schen Netz. Dies entspricht, wie zu Beginn des Kapitels ausführlich erläutert wurde, einer fixen Unsicherheit von 50%. Die A-priori-Wahrscheinlichkeit, die über das Bayes'sche Netz bestimmt wird, beschreibt jedoch nur den üblichen *Flow*. Diese Angabe enthält keinerlei Informationen über das detektierte Ereignis. Da Hyper-FlowCon in geringerem Maße auf die A-priori-Wahrscheinlichkeit zurückgreift, arbeitet es wesentlich genauer. Die Zahl der falsch erkannten Ereignisse beträgt, selbst bei einer Eingabe, die nur aus einem einzelnen Ereignis besteht, weniger als 5%.

Speziell diese Eingabeform zeigt, wie gut sich Glaubenszuweisungen der Dempster-Shafer-Theorie zur Darstellung von Unsicherheit eignen. Anstelle einer vollständigen Wahrscheinlichkeitsverteilung erhält Hyper-FlowCon nur die Angabe des wahrscheinlichsten Ereignisses, ohne jegliche Information zu den restlichen Möglichkeiten. Die Subjektive-Logik kann eine solche Angabe problemlos verarbeiten. Dabei wird die, durch die fehlenden Informationen entstandene Unsicherheit und Konfusion, durch eine vermehrte Verwendung der A-priori-Wahrscheinlichkeit ausgeglichen. Aus dieser Vorgehensweise resultiert eine geringere *Flow*-Sicherheit.

Der *Four-Condition-Evaluator* beeindruckt durch seine Einfachheit, die jedoch keinen nennenswerten positiven Effekt auf die Laufzeit hat. Vielmehr ist das Bayes'sche Netz – bzw. das verwendete Framework WEKA – der eigentlich begrenzende Faktor des Systems. Des Weiteren konnte der FOURCE, aufgrund seiner vier festen Werte, kein ähnlich gutes Ergebnis erzielen wie der SUBCE. Dies ist bedingt durch die Tatsache, dass sich die Operatoren im Ansatz sehr ähneln (vgl. Kapitel 3), jedoch die vier festen Werte der Vier-Wertigen-Logik weniger Möglichkeiten bieten als die *Opinions* der Subjektiven-Logik. Die Ergebnisse des FOURCE zeigen aber, dass die vom SUBCE erzeugten Ungleichungen korrekt sind und dass die Subjektive-Logik an dieser Stelle plausible Ergebnisse liefert.

Der neue Ansatz zur Bestimmung des Navigationsschwellwerts bringt, wie die Schaubilder der letzten Versuchsreihe bestätigen, nochmals eine deutliche Verbesserung. Die Ergebnisse zeigen ebenfalls, dass es theoretisch möglich ist, ein Kontext-Managementsystem zu verwenden, das nur das wahrscheinlichste Ereignis liefert. Hyper-FlowCon kann demnach mit fast jedem Kontext-Managementsystem kombiniert werden. Das Referenzsystem hingegen benötigt immer ein Kontext-Managementsystem, das eine vollständige Wahrscheinlichkeitsverteilung liefert. Die Verarbeitung einer Angabe, welche aus nur einem einzelnen Ereignis besteht, ist daher mit dem Referenzsystem nicht möglich.

5.4.1 Direkter Vergleich der Ergebnisse

Für das Kontext-Managementsystem, welches im Fall der Altenpflege eingesetzt wird, konnte die durchschnittliche Ereigniserkennung bestimmt werden. Nach K. Kunze u. a. [Kun+11] liegt diese bei 48 % und entspricht somit in etwa der simulierten Grundwahrheit von 45 %. Zum Vergleich sind in Abbildung 5.20 auf der nächsten Seite die Ergebnisse der drei Versuchsreihen für die genannte Grundwahrheit dargestellt. Die anschließende Abbildung 5.21 zeigt die Endergebnisse von Hyper-FlowCon im Vergleich zu FlowCon.

In Abbildung 5.20 ist gut zu erkennen, dass durch die Einführung des Vertrauensparameters die Varianz so gut wie keine Auswirkung mehr auf das Ergebnis hat. Der adaptive Navigationsschwellwert bringt nochmals eine deutliche Verbesserung bei der gegebenen Grundwahrheit von 45 %. Der FOURCE kann, wie in Abbildung 5.21 zu sehen ist, mit den Ergebnissen des SUBCE nicht mithalten. Der SUBCE liefert selbst für eine stark reduzierte Eingabe, bestehend aus nur einem einzelnen Ereignis, eine brauchbare Erkennungsrate.

Die Änderungen in Hyper-FlowCon haben, sowohl für diese als auch für alle anderen simulierten Grundwahrheiten, eine signifikante Verbesserung gebracht. Abbildung 5.21 zeigt sehr deutlich, dass Hyper-FlowCon unempfindlicher auf Rauschen und Varianz reagiert als FlowCon. Selbst bei einer reduzierten Eingabe ist kein Einbruch zu erkennen. Daher kann die Subjektive-Logik als geeignetes Unsicherheitsmodell für dieses Einsatzgebiet betrachtet werden.

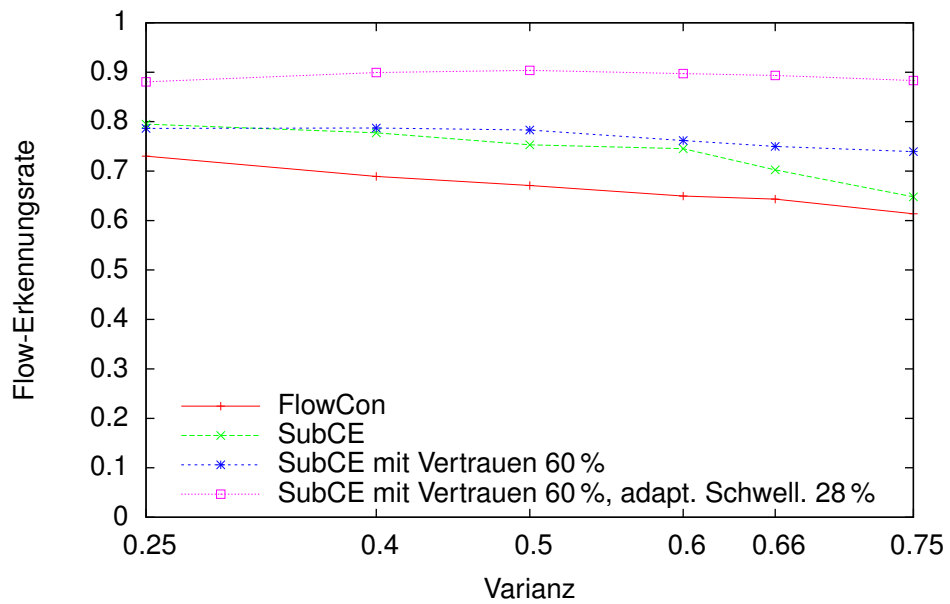


Abbildung 5.20: SUBCE im Vergleich zu FlowCon bei einer Grundwahrheit von 45 %

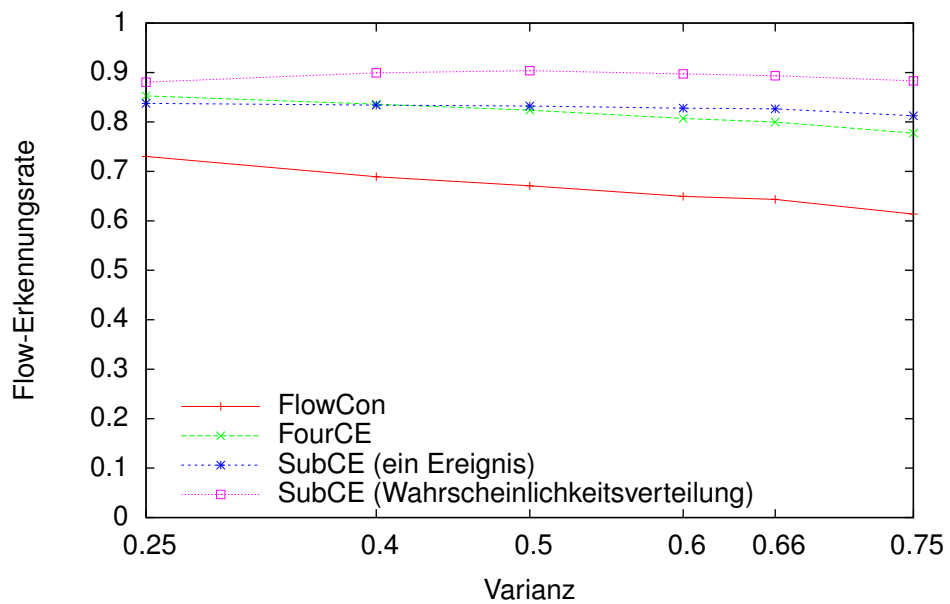


Abbildung 5.21: Endergebnisse im Vergleich zu FlowCon bei einer Grundwahrheit von 45 %

6 Zusammenfassung und Ausblick

Die Ergebnisse aus Kapitel 5 zeigen, dass die Wahl eines geeigneten Unsicherheitsmodells eine nachhaltige Auswirkung auf die Leistungsfähigkeit eines kontextbasierten Systems hat. Die in dieser Diplomarbeit entwickelte Erweiterung von FlowCon – welche als Hyper-FlowCon bezeichnet wird – weist eine um 50 % höhere Erkennungsrate auf als das ursprüngliche FlowCon. Allerdings erfüllt keines der Unsicherheitsmodelle aus Kapitel 3 alle gestellten Anforderungen. Hyper-FlowCon verwendet deshalb eine Kombination aus der Dempster-Shafer-Theorie und der Subjektiven-Logik.

Dabei nutzt Hyper-FlowCon Glaubenszuweisungen bzw. Glaubensfunktionen der Dempster-Shafer-Theorie als Eingabe. Das Ellsberg-Paradoxon zeigt, dass diese Glaubenszuweisungen Unsicherheit sehr präzise und auf verschiedenen Ebenen darstellen können. Sie sind daher als Eingabe für Hyper-FlowCon ideal geeignet. Im Gegensatz dazu würden die *Multinomial-Opinions* der Subjektiven-Logik, bedingt durch ihre striktere Definition, die Anzahl der möglichen Kontext-Managementsysteme stark einschränken. Durch Verwendung der Glaubenszuweisungen hingegen ist es möglich, dass Hyper-FlowCon mit Kontext-Managementsystemen verwendet wird, welches nur das wahrscheinlichste Ereignis liefert. Damit sind fast alle gängigen Systeme einsetzbar.

Zur Auswertung und inneren Verarbeitung erweist sich die Dempster-Shafer-Theorie in ihrer ursprünglichen Form aus folgenden Gründen als ungeeignet:

- Sie bringt einen exponentiellen Rechenaufwand mit sich.
- Es fehlen die für FlowCon nötigen Operatoren.
- Bei der Verwendung der zugehörigen Dempster'schen Kombinationsregel kommt es zu unintuitiven Ergebnissen.

An dieser Stelle erwies sich hingegen die Subjektive-Logik als ideales Unsicherheitsmodell:

- Sie hat die für FlowCon nötigen Operatoren.
- Ihre *Opinions* sind – im Gegensatz zu den Glaubensintervallen der Dempster-Shafer-Theorie – vergleichbar und sinnvoll auswertbar.
- Sie definiert einen klaren Zusammenhang zwischen den Informationen des Kontext-Managementsystems und der A-priori-Wahrscheinlichkeit, die über das interne Bayes'sche Netz von FlowCon bestimmt wird.

In Anbetracht der aufgezählten Gründe verwendet Hyper-FlowCon zur internen Verarbeitung die Subjektiven-Logik.

Damit Hyper-FlowCon die Glaubensintervalle mittels der Subjektiven-Logik auswerten kann, werden diese auf *Binomial-Opinions* abgebildet. Dieses Vorgehen entspricht weitgehend den *Hyper-Opinions* aus [JØS11].

Die *Opinions* der Subjektiven-Logik können als Dirichlet-Dichtefunktionen dargestellt werden. Sie entsprechen somit Wahrscheinlichkeitsverteilungen zweiter Ordnung. Hyper-FlowCon bestimmt aus den Angaben des Kontext-Managementsystems und der, durch das Bayes'sche Netz bestimmten, A-priori-Wahrscheinlichkeit die „wahrscheinlichste Wahrscheinlichkeitsverteilung“ für ein konkretes Ereignis bzw. für eine konkrete Situation. Die entstehenden *Opinions* beschreiben – neben dem Glauben – auch das Vorwissen, die Unsicherheit und die Konfusion des Betrachters. Sie weisen daher deutlich mehr Informationen auf als eine Verteilung, die direkt vom Kontext-Managementsystem stammt. Durch diesen Informationsgewinn ist es Hyper-FlowCon möglich, die Erkennungsrate deutlich zu steigern.

Zur Auswertung der Transitionsbedingungen erwiesen sich die *Binomial-Opinions* ebenfalls als ausgesprochen zweckmäßig. Sie besitzen einen Wahrscheinlichkeitswert, der es ermöglicht, den bestehenden *Binary-Condition-Evaluator* weiterzuverwenden. Ebenso ist es möglich, die *Binomial-Opinions* mit den Operatoren der Subjektiven-Logik auszuwerten, wodurch die Unsicherheit des Systems in die Auswertung der Transitionsbedingung einfließt. Es zeigt sich, dass die Operatoren der Subjektiven-Logik Unsicherheit reduzieren, wodurch die Auswertungen der Transitionsbedingungen an Qualität gewinnen. Demgemäß verwendet Hyper-FlowCon weniger A-priori-Wahrscheinlichkeit als das ursprüngliche FlowCon.

Die ebenfalls in dieser Diplomarbeit behandelte Vier-Wertige-Logik kann nur als Logik zum Auswerten der Transitionsbedingungen verwendet werden. Durch sie war es möglich, einen *Condition-Evaluator* zu erstellen, der zusätzlich die Wahrscheinlichkeitsverteilung – die aus den Informationen des Kontext-Managementsystems und des Bayes'schen Netzes bestimmt wird – auf Widersprüche prüft. Er brachte trotz der nur vier verschiedenen Werte der Vier-Wertigen-Logik eine deutliche Verbesserung. Allerdings war sie weniger deutlich als die des SUBCE.

Weitere *Condition-Evaluators* sind denkbar, da *Binomial-Opinions* beispielsweise auch als Glaubensintervall interpretiert werden können.

Bei den durchgeführten Versuchen konnte die Endversion von Hyper-FlowCon in jedem überprüften Bereich mehr als 80 % der *Flow*-Instanzen erkennen. Speziell im kritischen Bereich, bei geringer Grundwahrheit und starker Varianz, ergibt sich daraus eine relative Verbesserung von über 50 % im Vergleich zu FlowCon. Bei einer reduzierten Eingabe, die lediglich das wahrscheinlichste Ereignis enthält, verringert sich die Erkennungsrate nur minimal. Dies und die Eigenschaft, dass weniger Informationen aus dem Bayes'schen Netz verwendet werden, zeigt, dass die Wahl des Unsicherheitsmodells eine entscheidende Rolle für die Leistungsfähigkeit eines Systems spielt. Ausgehend von diesem Fazit ist es erstaunlich, dass viele Ausarbeitung – wenn überhaupt – nur den Ansatz der probabilistischen Logik zur Darstellung von Unsicherheit in Betracht ziehen.

Ausblick

Die Parameter in dieser Diplomarbeit wurden ohne aufwändige Optimierung eingestellt. Ausschlaggebend hierfür war die Tatsache, dass in der Praxis – unter realen Bedingungen – andere Effekte und Bedingungen herrschen als in einer Simulation. Eine Optimierung der einzelnen Parameter wäre aus diesem Grund wenig aussagekräftig gewesen. Wichtiger war es, dass die Parameter den gewünschten Erfolg erzielen. Die Parameter müssen einzelfallbezogen angepasst und optimiert werden. Dies zeigt aber auch, dass noch weiteres Verbesserungspotenzial besteht.

Ebenfalls ist eine weitere Verbesserung bei der Bestimmung der Unsicherheit denkbar. In dieser Diplomarbeit wurde die Unsicherheit über die Signifikanz bestimmt, was zu Problemen führte. Ein Klassifikator, der statt einer probabilistischen Wahrscheinlichkeitsverteilung eine *Multinomial-Opinion* liefert, bringt an dieser Stelle sicherlich eine weitere Verbesserung. Zusätzlich ist ein Klassifikator, der die Möglichkeiten einer Glaubenszuweisung völlig ausgeschöpft, denkbar. Beide Ansätze bieten Möglichkeiten, die Leistungsfähigkeiten weiter zu erhöhen.

Die Subjektive-Logik kann im Falle von FlowCon als ideales Unsicherheitsmodell angesehen werden. Sie stellt eine Verallgemeinerung der Wahrscheinlichkeitstheorie dar. Der vorgestellte Ansatz kann, wenn eine nutzbare Angabe der A-priori-Wahrscheinlichkeiten vorliegt, auf viele Systeme übertragen werden. Je nach Qualität der A-priori-Wahrscheinlichkeiten sind weitreichende Verbesserungen zu erwarten.

Ebenfalls zeigt diese Ausarbeitung, dass Workflows bzw. *Flows* eine Vielzahl an Informationen bereithalten, welche bei der Auswertung von Kontextinformationen sehr hilfreich sind. Die Zukunft wird zeigen, inwieweit die Kontext-Erkennung und Verarbeitung bei prozessbasierten, kontextbezogenen Anwendungen noch verbessert werden kann und in welche weiteren Einsatzgebiete der Ansatz von Hyper-FlowCon Anwendung findet.

Index

- A-priori-Wahrscheinlichkeit, 35, 38, 40, 41, 44, 45, 47, 49, 54, 86
Adaptable Pervasive Workflows, siehe Flows
Aktivität, 13
Anforderungen, 21

Base Rate, siehe A-priori-Wahrscheinlichkeit
Base Rate Vector, 38
Basic Belief Assignment, siehe Glaubenszuweisung
Basic Probability Assignment, siehe Glaubenszuweisung
Bayes'sche Regel, 46, 47
Bayes'sches Netz, 14, 29, 42, 46, 48, 53, 66, 69, 73, 76, 86
Belief Function, siehe Glaubensfunktion
Belief Mass Vector, siehe Glaubensvektor
Bernulli-Verteilung, 65, 68
Beta-Verteilung, 41
Betrachter, 33, 48
Betrachtungsrahmen, 22, 35, 38, 54, 56, 80
Bilattice, 30, 62

Condition, siehe Transitionsbedingung
Condition-Evaluator, 13, 54, 59, 63, 66
 Binary-Condition-Evaluator, 60, 70, 73, 76
 Four-Condition-Evaluator, 61, 73, 78, 82, 85, 87
 Subjective-Condition-Evaluator, 60, 61, 70, 73, 74, 76, 77, 80, 82, 85

Darstellungsnotation, 36, 48
 Evidenz-Notation, 40, 41
 Fuzzy-Kategorie, 40
 Glaubensnotation, 36, 40, 42
 Wahrscheinlichkeitsnotation, 40
degree of conflict, siehe Konfliktgrad
Dempster's rule of combination, siehe Dempster'sche Kombinationsregel
Dempster'sche Kombinationsregel, 25, 26, 48, 53
Dempster-Shafer-Theorie, 20, 22, 26, 28, 34, 35, 49, 53, 54, 56, 65
Dirichlet-Verteilung, 41, 42, 44, 49, 56
Disjunktion, 31, 42, 44, 45

Eingabeform, 66, 74
Ellsberg-Paradoxon, 19, 28, 33, 49, 53
Ereignisknoten, 54
Ereignistyp, 12, 56, 65, 80
Event-Instance, 12–14, 33, 54, 55
Evidenztheorie, 20, siehe Dempster-Shafer-Theorie

Fehl-Erkennungsrate, 66, 70, 77, 82, 86
Flow-Sicherheit, 72, 73
Flow-Erkennungsrate, 65, 67, 80, 86
Flow-Instanz, 66, 69
Flow-Modell, 13–15, 55, 65, 66
Flow-Sicherheit, 76–78, 82, 86
FlowCon, 11, 20, 28, 32, 42, 48, 53, 56, 63, 69, 74, 77, 80, 82, 86
Flows, 12
frame of discernment, siehe Betrachtungsrahmen

- Γ-Funktion, 41
- Glauben, 23, 34, 36, 44, 47, 54
- Glaubensfunktion, 24
- Glaubensintervall, 23–25, 35, 54
- Glaubensvektor, 38
- Glaubenswert, 23, 34, 38
- Glaubenszuweisung, 23–25, 38, 53, 56–59, 63, 65
- Ground-Truth*, siehe Grundwahrheit
- Grundwahrheit, 65–67, 73, 77

- Hyper-FlowCon, 55, 56, 62, 70, 73, 76, 78, 82, 86, 87

- Implikation, 32
- Inferenz, 32, 42, 45, 47–49
 - Abduktion, 46, 47
 - Deduktion, 46
- intersection tableau*, siehe Schnittmengentabelle

- Kleene-Logik \mathcal{K}_3 , 30, 37, 44, 45
- Kombinationsregel, siehe Dempster'sche Kombinationsregel
- Komplement, 31
- Komplexität, 26, 48, 53
- Konfliktgrad, 27
- Konfusion, 56, 86
- Konjunktion, 31, 42, 44
- Kontext-Managementsystem, 33, 48, 49, 53, 69, 73, 76, 86, 87
- Kontextinformationen, 11, 19, 49

- Lastgenerator, 65, 80

- Mittelung, 15, 69, 73, 86
- Modus-Pones, 45
- Modus-Tollens, 45

- Navigationsschwellwert, 13, 67, 80
- Negation, 31, 42, 45

- Opinion*, 34, 40, 41, 44, 46–48, 54, 55
 - Binomial*, 34–36, 41, 54, 55
 - dogmatisch, 37, 42, 49, 58
 - Hyper*, 56
 - Multinomial*, 35, 38, 39, 49, 53
 - Opinion-Simplex*, 36, 39, 46–48

- Plausibilität, 23
- Plausibilitätsfunktion, 24
- Plausibilitätswert, 24
- Plausibility Function*, siehe Plausibilitätsfunktion
- Potenzmenge, 23
- Pro-Contra-Tupel, 32, 61

- Rauschen, siehe Varianz
- Rechenaufwand, siehe Komplexität
- Referenzsystem, siehe FlowCon

- Schlussfolgerung, 33
- Schnittmengentabelle, 26
- Seed*, 65
- Sicherheit der Eingabe, 73
- Signifikanz, 58, 59, 63, 73, 76, 80
- Simulation, 66
- Subjektive-Logik, 33, 42, 47–49, 53, 54, 57, 60, 61, 63, 70, 73, 74, 78, 86, 87

- Transition, 13
- Transitionsbedingung, 13, 29, 33, 42, 48, 54, 55, 61, 70, 82

- UncertainEventProcessor*, 56
- Uncertainty Mass*, siehe Unsicherheitsmasse
- Unsicherheit, 17, 20, 25, 34, 37, 42, 46–49, 57, 59, 70, 73, 74, 76, 86
- Unsicherheitsbegrenzung, 61
- Unsicherheitsmasse, 38
- Unsicherheitsmaximierung, 47, 49
- Unsicherheitsmodell, 20, 74, 87

- Varianz, 65–67, 73
- Vektorfunktion, 38
- Versuchsreihen, 67
- Vertrauen, 67, 76, 78, 86
- Vier-Wertige-Logik, 30, 44, 45, 61, 73

Vorwissen, 48

Wahrheitsordnung, 30

Wahrscheinlichkeitsdichtefunktion, 40

Wahrscheinlichkeitsfunktion, 38

Wahrscheinlichkeitsprojektion, 37, 39, 40,
44, 49

Wahrscheinlichkeitsverteilung, 53, 65

Wahrscheinlichkeitswert, 37, 39, 41, 47, 48

Widerspruch, 62

Wissensdatenbank, 30

Wissensordnung, 30

Zweifelswert, 36, 38, 44, 54

Literatur

- [Amf+06] O. Amft u. a. „Sensing Muscle Activities with Body-Worn Sensors“. In: *Wearable and Implantable Body Sensor Networks, International Workshop on* 0 (2006), S. 138–141. DOI: 10.1109/BSN.2006.48 (siehe S. 11).
- [Bar81] J. A. Barnett. „Computational methods for a mathematical theory of evidence“. In: *IJCAI'81: Proceedings of the 7th international joint conference on Artificial intelligence*. Vancouver, BC, Canada: Morgan Kaufmann Publishers Inc., 1981, S. 868–875. DOI: 10.1007/978-3-540-44792-4_8. URL: <http://dl.acm.org/citation.cfm?id=1623319> (siehe S. 19, 22–24, 27, 57).
- [Bar91] J. A. Barnett. „Calculating Dempster-Shafer Plausibility“. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* 13 (1991), S. 599–602. DOI: 10.1109/34.87345 (siehe S. 27).
- [BB09] M. Berchtold und M. Beigl. „Increased Robustness in Context Detection and Reasoning Using Uncertainty Measures: Concept and Application“. In: *Ambient Intelligence, European Conference, Aml 2009, Salzburg, Austria, November 18-21, 2009. Proceedings*. Hrsg. von M. Tscheligi u. a. Bd. 5859. Lecture Notes in Computer Science. Springer, 2009, S. 256–266. ISBN: 978-3-642-05407-5. DOI: 10.1007/978-3-642-05408-2 (siehe S. 16).
- [BBA05] T. Barger, D. Brown und M. Alwan. „Health-status monitoring through analysis of behavioral patterns“. In: *Systems, Man and Cybernetics, Part A: Systems and Humans, IEEE Transactions on* 35.1 (Jan. 2005), S. 22–27. ISSN: 1083-4427. DOI: 10.1109/TSMCA.2004.838474 (siehe S. 16).
- [Bel77] N. D. Belnap Jr. „A Useful Four-Valued Logic“. In: *Modern uses of multiple-valued logic*. Hrsg. von J. M. Dunn und G. Epstein. Reidel, Dordrecht, 1977, S. 8–37 (siehe S. 21, 30–32).
- [Bis+10] J. Biswas u. a. „Health and wellness monitoring through wearable and ambient sensors: exemplars from home-based care of elderly with mild dementia“. In: *Annales des Télécommunications* 65.9-10 (2010), S. 505–521. DOI: 10.1007/s12243-010-0176-0 (siehe S. 17, 80).
- [CM00] P. Castro und R. Muntz. „Managing Context Data for Smart Spaces“. In: *IEEE Personal Communications* 7.5 (Okt. 2000), S. 44–46. DOI: 10.1109/98.878537 (siehe S. 16).

- [Dano03] M. Daniel. „Associativity in combination of belief functions; a derivation of minC combination“. In: *Soft Computing* 7.5 (2003), S. 288–296. DOI: 10.1007/s00500-002-0215-5 (siehe S. 28).
- [DD11] S. Destercke und D. Dubois. „Idempotent conjunctive combination of belief functions: Extending the minimum rule of possibility theory“. In: *Information Sciences* 181.18 (Sep. 2011), S. 3925–3945. ISSN: 0020-0255. DOI: 10.1016/j.ins.2011.05.007. URL: <http://www.sciencedirect.com/science/article/pii/S0020025511002507> (siehe S. 28).
- [Dez02] J. Dezert. „Foundations for a new theory of plausible and paradoxical reasoning“. In: *Information and Security* 9 (2002). Hrsg. von P. T. Semerdjiev (siehe S. 28).
- [DT11] J. Dezert und A. Tchamova. „On the behavior of Dempster’s rule of combination“. ENG. In: *Hyper Articles en Ligne* (März 2011). URL: <http://hal.archives-ouvertes.fr/hal-00577983/en/> (siehe S. 27, 28).
- [Ell61] D. Ellsberg. „Risk, ambiguity, and the Savage axioms“. In: *The Quarterly Journal of Economics* 75.4 (Nov. 1961), S. 643–669. DOI: 10.2307/1884324. URL: <http://www.jstor.org/stable/1884324> (siehe S. 19, 20).
- [Fit91] M. C. Fitting. „Bilattices and the Semantics of Logic Programming“. In: *Journal of Logic Programming* 11.1–2 (Juli 1991), S. 91–116. DOI: 10.1016/0743-1066(91)90014-G (siehe S. 30).
- [Gin88] M. L. Ginsberg. „Multivalued Logics: A Uniform Approach to Inference in Artificial Intelligence“. In: *Computational Intelligence* 4 (1988), S. 265–316 (siehe S. 30, 32).
- [Gin90] M. L. Ginsberg. „Bilattices and Modal Operators“. In: *Journal of Logic and Computation* 1.1 (Juli 1990), S. 41–69. DOI: 10.1093/logcom/1.1.41 (siehe S. 30, 31).
- [GS84] J. Gordon und E. H. Shortliffe. „The Dempster-Shafer Theory of Evidence“. In: *Rule-Based Expert Systems*. Hrsg. von B. G. Buchanan und E. H. Shortliffe. Reading, Massachusetts: Addison Wesley Publishing Company, 1984, S. 272–292 (siehe S. 25).
- [Hae05] R. Haenni. „Shedding New Light on Zadeh’s Criticism of Dempster’s Rule of Combination“. In: *8th International Conference on Information Fusion*. Bd. 2. 2005, S. 879–884. DOI: 10.1109/ICIF.2005.1591951 (siehe S. 28).
- [Her+08] K. Herrmann u. a. „Adaptable Pervasive Flows—An Emerging Technology for Pervasive Adaptation“. In: *Proceedings of the 2008 Second IEEE International Conference on Self-Adaptive and Self-Organizing Systems Workshops*. IEEE Computer Society. 2008, S. 108–113. DOI: 10.1109/SASOW.2008.25. URL: http://www.ipvs.uni-stuttgart.de/abteilungen/vs/abteilung/mitarbeiter/klaus.herrmann_infos/pubpdfs/sasow08.pdf (siehe S. 9).

- [JMo4] A. Jøsang und D. McAnally. „Multiplication and comultiplication of beliefs“. In: *International Journal Approximate Reasoning* 38.1 (2004), S. 19–51. DOI: 10.1016/j.ijar.2004.03.003. URL: <http://folk.uio.no/josang/publications.html> (siehe S. 37, 44, 45).
- [JMPo6] A. Jøsang, S. Marsh und S. Pope. „Exploring Different Types of Trust Propagation“. In: *Trust Management – 4th International Conference, iTrust 2006, Pisa, Italy, May 16-19, 2006, Proceedings*. Hrsg. von K. Stølen u. a. Bd. 3986. Lecture Notes in Computer Science. Pisa, Italy: Springer, Mai 2006, S. 179–192. ISBN: 3-540-34295-8. DOI: 10.1007/11755593_14. URL: <http://folk.uio.no/josang/publications.html> (siehe S. 48).
- [Jøso1] A. Jøsang. „A Logic for Uncertain Probabilities“. In: *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems* 9.3 (2001), S. 279–212. DOI: 10.1142/S0218488501000831. URL: <http://folk.uio.no/josang/publications.html> (siehe S. 36, 40, 45, 76).
- [Jøso7] A. Jøsang. „Probabilistic Logic under Uncertainty“. In: *Thirteenth Computing: The Australasian Theory Symposium (CATS2007)*. Hrsg. von J. Gudmundsson und B. Jay. Bd. 65. CRPIT. Ballarat, Australia: ACS, 2007, S. 101–110. ISBN: 1-920-68246-5. URL: <http://crpit.com/confpapers/CRPITV65Josang.pdf> (siehe S. 19, 34, 38, 41, 76).
- [Jøso8] A. Jøsang. „Conditional Reasoning with Subjective Logic“. In: *Journal of Multiple-Valued Logic and Soft Computing* (2008), S. 5–38. URL: <http://eprints.qut.edu.au/14842/> (siehe S. 45–48).
- [Jøso10] A. Jøsang. „Subjectiv Logic“. Draft book. Juli 2010. URL: <http://folk.uio.no/josang/publications.html> (siehe S. 33–35, 37, 38, 40–48, 57, 63, 76).
- [Jøso11] A. Jøsang. „Subjectiv Logic“. Draft book. Sep. 2011. URL: <http://folk.uio.no/josang/publications.html> (siehe S. 34, 36, 39, 40, 48, 56, 90).
- [Jøso97] A. Jøsang. „Artificial reasoning with subjective logic“. In: *In 2nd Australian Workshop on Commonsense Reasoning*. 1997. URL: <http://folk.uio.no/josang/publications.html> (siehe S. 33, 40, 44, 54).
- [JP10] A. Jøsang und S. Pope. „Dempster’s Rule as Seen by Little Coloured Balls“. In: *Computational Intelligence Journal* (2010). in press. URL: <http://folk.uio.no/josang/publications.html> (siehe S. 28).
- [JPD05] A. Jøsang, S. Pope und M. Daniel. „Conditional Deduction Under Uncertainty“. In: *Symbolic and Quantitative Approaches to Reasoning with Uncertainty, 8th European Conference, ECSQARU 2005, Barcelona, Spain, July 6-8, 2005, Proceedings*. Hrsg. von L. Godo. Bd. 3571. Lecture Notes in Computer Science. Springer, 2005, S. 824–835. ISBN: 3-540-27326-3. DOI: 10.1007/11518655_69. URL: <http://folk.uio.no/josang/publications.html> (siehe S. 40, 48).

- [KI08] G. Kern-Isberner. *Commonsense Reasoning*. Vortragsfolien. Apr. 2008. URL: <http://ls6-www.cs.uni-dortmund.de/index.php?id=33&p=65&l=1&w=0> (siehe S. 32).
- [Kun+11] K. Kunze u. a. *Final report on the integration of context recognition*. Deliverable D2.3. ALLOW Consortium, Aug. 2011 (siehe S. 87).
- [Lau+09] J. M. Lau u. a. „Discovery and Analysis of Activity Pattern Cooccurrences in Business Process Models“. In: *ICEIS 2009 - Proceedings of the 11th International Conference on Enterprise Information Systems, Volume ISAS, Milan, Italy, May 6-10, 2009*. Hrsg. von J. Cordeiro und J. Filipe. 2009, S. 83–88. ISBN: 978-989-8111-86-9 (siehe S. 65).
- [Lv91] P. Lucas und L. van der Gaag. „Principles of Expert Systems“. In: *International Computer Science Series*. Addison-Wesley Publishing Company, Okt. 1991. Kap. 5.6, S. 300–312 (siehe S. 22–26, 29, 57).
- [PD10] F. Pichon und T. Denoëux. „The Unnormalized Dempster’s Rule of Combination: A New Justification from the Least Commitment Principle and Some Extensions“. In: *J. Autom. Reasoning* 45.1 (2010), S. 61–87. DOI: 10.1007/s10817-009-9152-7 (siehe S. 28).
- [RNo4] S. Russell und P. Norvig. *Künstliche Intelligenz – Ein moderner Ansatz*. PEARSON Studium, 2004. ISBN: 978-3827370891 (siehe S. 25, 46).
- [SBG99] A. Schmidt, M. Beigl und H.-W. Gellersen. „There is more to context than location“. In: *Computers and Graphics* 23.6 (1999), S. 893–901. ISSN: 0097-8493. DOI: 10.1016/S0097-8493(99)00120-X (siehe S. 15).
- [SF02] K. Sentz und S. Ferson. *Combination of evidence in Dempster-Shafer theory*. Techn. Ber. Sandia National Laboratories, Albuquerque, New Mexico 87185 und Livermore, California 94550: Sandia National Laboratories, Apr. 2002 (siehe S. 27).
- [Sha92] G. Shafer. „Response to the Discussion of Belief Functions“. In: *International Journal of Approximate Reasoning* (1992) (siehe S. 25, 29, 50).
- [Tsoo2] A. Tsoukiàs. „A first-order, four valued, weakly paraconsistent logic and its relation to rough sets semantics“. In: *Foundations of Computing and Decision Sciences* 12 (2002), S. 85–108 (siehe S. 31, 32).
- [Urb+09] S. Urbanski u. a. „PerFlows for the computers of the 21st century“. In: *Pervasive Computing and Communications, 2009. PerCom 2009. IEEE International Conference on*. 2009, S. 1–6. DOI: 10.1109/PERCOM.2009.4912887 (siehe S. 15).
- [Web98] S. Weber. „Investigations in Belnap’s Logic of Inconsistent and Unknown Information“. Diss. der Fakultät für Mathematik und Informatik der Universität Leipzig, 1998 (siehe S. 30).

- [WHR10] H. Wolf, K. Herrmann und K. Rothermel. „Robustness in Context-Aware Mobile Computing“. In: *IEEE International Conference on Wireless and Mobile Computing, Networking and Communications (WiMob'2010)*. Niagara Falls, Canada, Okt. 2010. DOI: 10.1109/WIMOB.2010.5645026 (siehe S. 9, 12, 14, 15, 48, 65, 80).
- [Wie+09] M. Wieland u. a. „Towards Integration of Uncertain Sensor Data into Context-aware Workflows“. English. In: *Tagungsband INFORMATIK 2009 Im Focus das Leben, 39. Jahrestagung der Gesellschaft für Informatik e.V. (GI)*. Hrsg. von G.-E. L. N. in Informatics (LNI). Lübeck: Lecture Notes in Informatics (LNI), 2009. URL: http://www.informatik.uni-stuttgart.de/cgi-bin/NCSTRL/NCSTRL_view.pl?id=INPROC-2009-64&engl=1 (siehe S. 16).
- [WPH11] H. Wolf, J. Palauro und K. Herrmann. „Fuzzy Event Assignment for Robust Context-Aware Workflows“. In: *Proceedings of The Fourth International Conference on Dependability (DEPEND 2011)*. Hrsg. von IARIA. Nice/Saint Laurent du Var, France: IARIA, 2011, S. 37–42. ISBN: 978-1-61208-149-6 (siehe S. 65).
- [Zad86] L. A. Zadeh. „A Simple View of the Dempster-Shafer Theory of Evidence and its Implication for the Rule of Combination“. In: *AI Magazine* 7 (1986), S. 85–90. URL: <http://www.aaai.org/ojs/index.php/aimagazine/article/view/542> (siehe S. 26, 27).

Alle URLs wurden zuletzt am 27. November 2011 geprüft.

Erklärung

Hiermit versichere ich, diese Arbeit selbständig verfasst und nur die angegebenen Quellen benutzt zu haben.

(Michael Trunner)