

Bayes'sche Methodik zur lokalen Fusion heterogener Informationsquellen

*Jürgen Beyerer, Fraunhofer-Institut, Karlsruhe,
Jennifer Sander, Stefan Werling, Universität Karlsruhe*

Manuskripteingang: 05. Januar 2007; zur Veröffentlichung angenommen: 08. Januar 2007

Bei der Fusion heterogener Informationsquellen muss deren unterschiedlicher Abstraktionsgrad und deren unterschiedliche Natur (Formalisierung) überwunden werden. Essenzielle Forderungen an eine Fusionsmethodik sind die Fähigkeiten zur Transformation, Fusion und Fokussierung. Es wird gezeigt, dass die Bayes'sche Wahrscheinlichkeitstheorie in einer Degree-of-Belief-Deutung jede dieser Forderungen erfüllt. Um ihren hohen Rechenaufwand entscheidend zu verringern, wird anschließend ein lokaler Bayes'scher Fusionsansatz vorgestellt. Dieser kann in Anlehnung an kriminalistische Ermittlungen mittels einer agentenbasierten Fusionsarchitektur umgesetzt werden.

Schlagwörter: Heterogene Informationsquellen, Bayes'sche Fusionsmethodik, lokaler Fusionsansatz, Kriminalistik, Degree-of-Belief-Deutung von Wahrscheinlichkeit

Bayesian Methodology for the Local Fusion of Heterogeneous Information Sources

In fusing heterogeneous information sources, their different abstraction levels and formalizations have to be coped with. Essential requirements on a fusion methodology are its abilities to transform, fuse, and focus. It is shown that the Bayesian fusion methodology as Degree-of-Belief interpretation covers all these areas. With a view to reduce high computational costs, a local approach for the Bayesian fusion of information is subsequently be presented. In analogy to criminalistic investigation, this approach can be realized via agent-based fusion architecture.

Keywords: Heterogeneous information sources, Bayesian fusion methodology, local fusion approach, criminalistics, Degree-of-Belief interpretation of probability

1 Einleitung

Unter Informationsfusion versteht man das Zusammenführen, Überlagern und Nutzen der Informationsbeiträge mehrerer Informationsquellen im Hinblick auf eine gegebene Aufgabenstellung. Der Begriff Information steht dabei für alles, das potenziell zur Verminderung

einer vorhandenen Ungewissheit beitragen kann. Information kann in unterschiedlichen Formalisierungen und Abstraktionsniveaus vorliegen. Repräsentationsformen von Information sind u. a. Vorwissen, Daten, Signale, Merkmale, Entscheidungen oder die Aussagen menschlicher Beobachter. Ein Maß für Information ist die durch ihr Hinzukommen beseitigte Ungewissheit. Information

ist vollständig spezifiziert durch Angabe von Fakten, der zugehörigen Unsicherheiten sowie einer Beschreibung der Abhängigkeiten zwischen den Informationsbeiträgen der einzelnen Quellen.

Ein besonderes Potenzial liegt in der Fusion heterogener Informationsquellen, da diese oft unterschiedliche Stärken und Schwächen haben und sich dadurch gegenseitig ergänzen. Zusätzlich setzt die Lösung der meisten anwendungsbezogenen Aufgaben in unterschiedlichen wissenschaftlichen Disziplinen die effiziente Ausnutzung und Kombination einer großen Menge heterogener Informationsquellen voraus. Als Beispiel seien die militärische oder zivile Aufklärung, die automatische Sichtprüfung sowie die kognitive Robotik erwähnt.

2 Anforderungen an eine Fusionsmethodik

Basisanforderungen an eine Fusionsmethodik sind ihre Fähigkeiten zur

- Transformation,
- Fusion und
- Fokussierung.

Diese drei essenziellen Forderungen an eine Fusionsmethodik sind nötig für ein qualitativ hochwertiges, differenziertes und aufgabenspezifisches Fusionsresultat mit minimaler Restunsicherheit.

Die Fähigkeit zur Transformation bedeutet, dass die Fusionsmethodik unterschiedlich stark abstrahierte und formalisierte Informationsbeiträge möglichst unverfälscht in eine einheitliche mathematische Beschreibung umsetzen kann. Dazu muss ein gegebener Informationsbeitrag je nach seinem Abstraktionsgrad relativ zur angestrebten mathematischen Beschreibung artefaktarm spezialisiert, mit geringer Unsicherheit gewandelt (bei konstantem Abstraktionsniveau) oder verlustarm abstrahiert werden.

Dabei kann es technisch vorteilhaft sein, Gruppen strukturell ähnlicher Informationsbeiträge zunächst auf geeigneten Zwischenniveaus zusammenzuführen und so die Transformation auf die final verwendete mathematische Beschreibung zur Fusion und Fokussierung schrittweise durchzuführen. Vorteilhaft ist außerdem eine möglichst zwanglose simultane Handhabung unterschiedlich skaliert Größen. Die Transformation der Informationsbeiträge heterogener Quellen homogenisiert diese in einer Weise, dass sie nachher mathematisch kompatibel, d. h. einheitlich beschrieben sind.

Anschließend müssen Methoden verfügbar sein, durch die die transformierten Informationsbeiträge der verschiedenen Quellen verschmolzen werden. Dies ist die Fähigkeit zur Fusion.

Die daraus resultierende umfassende Informationsverkörperung der Gesamtaufgabe muss fokussierbar

sein, d. h. sie muss auf spezielle Einzelfragestellungen konzentriert werden können.

Weitere wünschenswerte Eigenschaften einer praktikablen Fusionsmethodik sind: Durchschaubarkeit, modulare Erweiterbarkeit sowie die Möglichkeit, sie den verfügbaren Ressourcen optimal anzupassen.

Als methodische Ansätze kommen insbesondere die Bayes'sche Wahrscheinlichkeitstheorie, die Fuzzy-Theorie sowie die Evidenztheorie von Dempster-Shafer in Betracht. Verzichtet man auf eine Differenzierung von Unsicherheiten hinsichtlich ihrer Ursachen und Natur (Messunsicherheit, Unbestimmtheit, Ungewissheit, ...), was für die meisten realen Aufgabenstellungen einen sinnvollen pragmatischen Standpunkt darstellt, so ist die Bayes'sche Wahrscheinlichkeitstheorie eine hinreichend mächtige Plattform für die mathematische Beschreibung und Durchführung von Fusion. Vorteile dieser Theorie sind ihr schlankes und elegantes Kalkül, ihr hoher Reifegrad und ihre Verbreitung, ihre Anschaulichkeit aber auch die Intuition, die der Nutzer für Wahrscheinlichkeitsbegriffe i. d. R. mitbringt.

3 Die Bayes'sche Fusionsmethodik

3.1 Formulierung der Fusionsaufgabe

Der erste Schritt vor Durchführung der eigentlichen Fusionsaufgabe besteht in der Festlegung des Fensters des Interesses z , das den Bezugsrahmen in zeitlicher, räumlicher und thematischer Hinsicht schafft: Durch den Vektor

$$z := (z_1, \dots, z_N) \in Z := Z_1 \times \dots \times Z_N$$

werden jene Parameter des nicht direkt beobachtbaren „state of the nature“ festgelegt, die abhängig von der gegebenen Aufgabenstellung auszuwerten sind. In praktischen Anwendungen werden die Komponenten von z unterschiedliche Skalierungen aufweisen, sodass nur zulässige informationserhaltende Transformationen angewandt werden dürfen.

Bezeichnet weiter d_s den von der Quelle Nummer s gelieferten Informationsbeitrag, so lässt sich durch den Vektor

$$d := (d_1, \dots, d_S) \in D := D_1 \times \dots \times D_S$$

die gesamte von den Quellen gelieferte Information zusammenfassen.

In der Bayes'schen Methodik werden deterministische und zufallsbehaftete Größen formal als Zufallsvariablen aufgefasst und mit einer *gemeinsamen*

Wahrscheinlichkeitsverteilung (WV) $P(z, d)$ beschrieben, was den Bayes'schen Kalkül im Vergleich zur klassischen Interpretation symmetriert. Für eine sinnvolle Fusion ist es natürlich notwendig, dass sich alle zu nutzenden Quellen auf dasselbe Geschehen beziehen, also derselbe „state of the nature“ zugrunde liegt und mithin die Verteilung $P(z, d)$ existiert.

Zur Charakterisierung von WV werden im diskreten Fall Wahrscheinlichkeitsfunktionen und im kontinuierlichen Fall Wahrscheinlichkeitsdichtefunktionen gewählt.

3.2 Degree-of-Belief-Interpretation von Wahrscheinlichkeiten

Grundlage der Wahrscheinlichkeitstheorie sind die drei Kolmogorov'schen Axiome. Diese definieren Wahrscheinlichkeiten formal, legen gewissermaßen die Syntax fest. Sie deuten Wahrscheinlichkeiten jedoch nicht, lassen so den semantischen Aspekt offen.

Die beiden wichtigsten Interpretationen (Deutungen) sind die frequentistische Deutung, bei der Wahrscheinlichkeiten als Grenzwerte relativer Häufigkeiten aufgefasst werden, sowie die Degree-of-Belief (DoB)-Deutung, die in der Bayes'schen Theorie verwendet wird. Bei letzterer repräsentiert die Wahrscheinlichkeit eines Ereignisses den Grad an Gewissheit bezüglich dessen Eintreten unter Berücksichtigung der gegebenen Fakten und Annahmen. Wahrscheinlichkeit hat in der DoB-Deutung stets bedingten Charakter, sie ist abhängig vom aktuellen Informationsstand. Als Konsequenz wird sich eine Zunahme an Information in einer Konzentration der korrespondierenden DoB-Verteilung widerspiegeln.

Im Allgemeinen hängt der DoB von der definierenden Person ab, da das subjektive Vertrauen verschiedener Individuen in das Eintreten ein und desselben Ereignisses auch bei Vorliegen gleicher Information unterschiedlich stark sein wird. Wahrscheinlichkeit wird so zum subjektiven Ausdruck für den Grad des Dafürhaltens. DoB-Verteilungen lassen sich aber auch anhand objektiver Mechanismen aus gegebenen Fakten ableiten. Ein Beispiel ist das Prinzip der Maximalen (Informations-)Entropie (ME); siehe Abschnitt 3.3. Mit solchen Prinzipien kommen dann auch unterschiedliche Individuen bei gleichen Fakten zu gleichen DoB-Verteilungen.

Im Folgenden wird Wahrscheinlichkeit grundsätzlich als DoB aufgefasst, der so weit wie möglich mit objektiven Verfahren eruiert wird.

3.3 Transformation

Ein einfacher aber theoretisch gut begründeter Mechanismus zur artefaktarmen Transformation ist das

ME-Prinzip [6; 7]. Dabei wird die DoB-Verteilung mit maximaler Shannon'scher Entropie – unter Betrachtung der gegebenen Fakten als Nebenbedingung – berechnet:

$$P_{\text{ME}}(x) = \arg \max_{P(x) \in \Pi} \{ \mathbf{E}\{-\log P(x)\} \}$$

$$\Pi := \{ P(x) \mid (P(x) \text{ ist eine WV}) \\ \wedge (P(x) \text{ ist mit den Fakten verträglich}) \}$$

Die Entropie ist ein Maß für die Unsicherheit. Nur die gegebenen Fakten verringern die Unsicherheit bezüglich x und mithin werden diese ohne ungewollte implizite Einbeziehung artefaktischer Fakten in eine DoB-Verteilung transformiert. Die Transformation mittels des ME-Prinzips entspricht einer Spezialisierung.

Wird als Faktum z. B. ein beschränkter Wertebereich für x vorgegeben, was äquivalent zu einem beschränkten Träger $X = \text{supp}\{P(x)\}$ ist, resultiert als ME-Verteilung eine Gleichverteilung auf X . Sind die Fakten z. B. ein quantitativer Wert ξ und eine zugehörige Unsicherheit σ_ξ , die als Erwartungswert und Standardabweichung interpretiert werden können, ist die ME-Verteilung eine Normalverteilung $N(\xi, \sigma_\xi^2)$.

Für den wichtigen Fall von Fakten in Form von Erwartungswerten

$$\mathbf{E}\{k_l(x)\} = \kappa_l, \quad l = 1, \dots, L \quad (1)$$

erhält man die geschlossene Lösung

$$P_{\text{ME}}(x) = \lambda_0 \exp \left\{ \sum_{l=1}^L \lambda_l k_l(x) \right\},$$

wobei die Konstanten λ_l anhand der Nebenbedingungen (1) zu bestimmen sind.

3.4 Fusion

Nach der Transformation der Informationsbeiträge aller Quellen in DoB-Verteilungen leistet die Bayes'sche Formel die eigentliche Fusion. Seien der Einfachheit halber zwei Informationsquellen gegeben, die die Beobachtungen d_1 und d_2 liefern. Diese seien entsprechend dem „state of the nature“ z durch die Likelihoodfunktionen $P(d_1|z)$ bzw. $P(d_2|z)$ beschrieben. Eine verlustfreie – im Sinne von: kein Shannon'scher Informationsverlust – Inferenz bezüglich z liefert als Endergebnis die *A-posteriori*-DoB-Verteilung $P(z|d_1, d_2)$ [13]. Hierfür gilt:

$$P(z|d_1, d_2) \propto P(d_1, d_2|z)P(z) = P(d_1|d_2, z)P(d_2|z)P(z) \\ \stackrel{(A)}{=} P(d_1|z)P(d_2|z)P(z), \quad (2)$$

wobei die Gleichheit (A) dann gilt, wenn d_1 und d_2 bei Festhalten der gemeinsamen Ursache z unabhängig sind.

Das ist praktisch anzunehmen, wenn z. B. d_1 und d_2 mittels unterschiedlicher Sensorprinzipien ermittelt werden und die den beiden Kanälen überlagerten Störungen unabhängig sind.

Laut Gl. (2) geschieht die Fusion im Bayes'schen Kontext im Wesentlichen durch die Multiplikation der beiden Likelihoodfunktionen mit der *A-priori*-Verteilung $P(z)$. Genau genommen werden in diesem Beispiel sogar drei Quellen fusioniert, sieht man das *A-priori*-Wissen ebenfalls als solche an.

3.5 Fokussierung durch Marginalisierung

In der *A-posteriori*-DoB-Verteilung $P(z|d)$ sind die Informationsbeiträge aller Quellen zusammengeführt und liefern vereint den DoB bezüglich der Größen des Interesses z_1, \dots, z_N . Für die Beantwortung spezieller Fragen einer Aufgabenstellung muss die gesamthafte Aussage der DoB-Verteilung i. d. R. weiter verdichtet werden, was aber im Shannon'schen Sinne mit einem Informationsverlust einhergeht.

Beschreiben beispielsweise in einer konkreten Problemstellung z_1, z_2 und z_3 den Ort, z_4 die Zeit, z_5, z_6 und z_7 die Orientierung und z_8 den Typ eines Fahrzeuges, und geht es darum, das Fahrzeug zu detektieren und vornehmlich Aufenthaltsort und -zeit zu bestimmen, ist eine Fokussierung auf z_1, z_2, z_3 und z_4 sinnvoll. Die Größen z_5, z_6, z_7 und z_8 spielen dann die Rollen sogenannter „Nuisance“-Parameter, die aus der *A-posteriori*-DoB-Verteilung herausintegriert bzw. -summiert werden:

$$P(z_1, \dots, z_4|d) = \int_{z_5 \in Z_5} \int_{z_6 \in Z_6} \int_{z_7 \in Z_7} \sum_{z_8 \in Z_8} P(z_1, \dots, z_8|d) dz_5 dz_6 dz_7.$$

Diese sogenannte Marginalisierung führt zu einer Reduzierung der Dimensionalität des Problems und erlaubt die gewünschte Fokussierung im Rahmen der Bayes'schen Methodik.

Ein zweiter Mechanismus zur Fokussierung ist die Bildung von *A-posteriori*-Erwartungswerten einer problemspezifischen Funktion $f(z)$ auf Z

$$E\{f(z)\} = \int \sum f(z) P(z|d) dz, \tag{3}$$

wobei über die diskreten Komponenten von z summiert und über die kontinuierlichen integriert wird. Hängt $f(z)$ nicht von allen Komponenten von z ab, impliziert Gl. (3) auch eine Marginalisierung.

Damit ist gezeigt, dass die Bayes'sche Methodik für jede der drei Forderungen nach Transformation, Fusion und Fokussierung geeignete Mechanismen zur

Verfügung stellt. Der Bayes'sche Formalismus kann außerdem zwanglos simultan mit kontinuierlichen und diskreten Größen und unterschiedlichen Skalenniveaus umgehen.

4 Ein lokaler Ansatz zur Bayes'schen Fusion

4.1 Die wesentliche Herausforderung

Bei praktisch relevanten Aufgaben kann die Dimension N des Raumes Z der interessierenden Größen recht groß sein. Trotz aller sonstigen Vorteile des Bayes'schen Formalismus wächst seine Komplexität exponentiell mit N . So wäre in Gl. (3) z. B. eine N -dimensionale Summation/Integration durchzuführen mit einem Aufwand $O(\prod_{i=1}^N |Z_i|)$, der auch bei moderater Größenordnung von N i. d. R. nicht tragbar ist.

Ein in [1; 11] vorgestellter Ansatz löst dieses Problem durch Einnahme eines lokalen Standpunkts, mit dem Ziel, Bayes'sche Inferenz und Fusion nur dort lokal in Z vorzunehmen, wo sich auch tatsächlich Aufgabenrelevantes abspielt. Dabei wird eine Analogie zur kriminalistischen Ermittlung hergestellt, also zu einem ausgereiften, funktionierenden Prozess der realen Welt. Das inspirierte zu einer agentenbasierten Fusionsarchitektur, in der Fusionsagenten Spuren und Hypothesen lokal verfolgen und weiterentwickeln.

4.2 Ein Blick über den Tellerrand: Kriminalistische Ermittlungen

In einem kleinen Exkurs soll ein vereinfachter Blick auf kriminalistische Ermittlungen geworfen und die für die Fusion relevanten Vorgehensweisen aufgezeigt werden.

Am Anfang steht ein Sachverhalt, dessen Ursachen aufzuklären sind. Vorhandene Spuren: Indizien, Hinweise usw. werden Ermittlern übertragen, die diese verfolgen, daraus Hypothesen generieren und diese Hypothesen anhand der weiteren Ermittlungen zu erhärten oder zu verwerfen versuchen. Im Erfolgsfall wird der Grad des Dafürhaltens (DoB) einzelner Hypothesen so groß, dass man sie als bewiesen betrachtet. Entlang der Untersuchung wird ein Ermittler mit heterogenen Informationen konfrontiert: Zeugenaussagen, Fingerabdrücke, Reifenspuren, DNA-Spuren usw., die er in einen Zusammenhang bringen, also gewissermaßen fusionieren muss. Für viele dieser Evidenzen ist der Ermittler kein Experte, sodass er Sachverständige konsultiert, die ihm konkrete Spuren auswerten und ihm ein für ihn verständliches Resultat zurückliefern, das dann seinen DoB

beeinflusst. Ermittler kommunizieren miteinander, um ihre Wissensstände abzugleichen und ihre beschränkten Sichten zu einem Ganzen zu verschmelzen. Am Ende des Ermittlungsprozesses sollten dann finale Hypothesen stehen sowie eine Bewertung ($\hat{=}$ DoB), wie sicher man sich über das Ergebnis ist.

Charakteristisch sind die heterogenen Informationsquellen und die lokale Sicht der einzelnen Ermittler. Sie haben keinen „god's view“ auf den ganzen Raum des Interesses, sondern sehen zunächst nur die Spuren und den sie lokal einbettenden Kontext.

4.3 Agentenbasierte Fusionsarchitektur

Für die verfügbaren Quellen, die alle einen Bezug zum gleichen zugrunde liegenden Sachverhalt haben, werden in einer Initialisierung Spuren gewonnen, die als zu prüfende Hypothesen an Fusionsagenten (FA) übergeben werden. Die FAs suchen dann sequenziell die verbleibenden Quellen auf mit dem Ziel, den DoB ihrer Spuren dort zu erhärten oder zu entkräften. Nach dem Besuch aller Quellen kann über die Annahme der Hypothesen anhand ihrer finalen DoBs entschieden werden.

Wesentlich dabei ist, dass jede Spur $c \in Z$ lokal nur in einer kleinen Umgebung $U = U(c) \subset Z$, $|U| \ll |Z|$ im Fenster des Interesses betrachtet wird und die Fusion nur lokal in $U(c)$ stattfindet. Das senkt den Aufwand von $O(|Z|)$ auf $O(C|U|)$, wobei C die Zahl der Spuren ist.

Im Hinblick auf eine gegebene Aufgabenstellung und unter Berücksichtigung von Z und $P(z)$ wird auf jede der Quellen ein quellspezifischer Operator $I_s\{\}$, $s = 1, \dots, S$, zur Erzeugung lokaler Auffälligkeiten in Z angewandt. $I_s\{\}$ soll dabei optimal auf die Quelle s abgestimmt sein, sodass er bei isolierter Betrachtung von d_s das bestmögliche Detektionsergebnis für lokale Auffälligkeiten hervorbringt. Er verkörpert somit die vorhandene Expertise zur Auswertung der Quelle s alleine.

Besteht die Fusionsaufgabe beispielsweise darin, Fahrzeuge zu finden und zu klassifizieren, und ist d_s ein Luftbild, so sollte der Operator $I_s\{\}$ ein Resultat $i(z|d_s) = I_s\{d_s\}$ über

$$Z^s = [x_{\min}, x_{\max}] \times [y_{\min}, y_{\max}] \times \{\text{relevante Fahrzeugtypen}\} \subseteq Z$$

liefern, das lokale Maxima für vorhandene Fahrzeuge haben soll. Ausgeprägte lokale Maxima und deren Argumente $z = c_{s,r} \in Z^s$

$$\{c_{s,r}\} := \arg_{z \in Z^s} \{\text{signifikante lokale Maxima von } i(z|d_s)\}$$

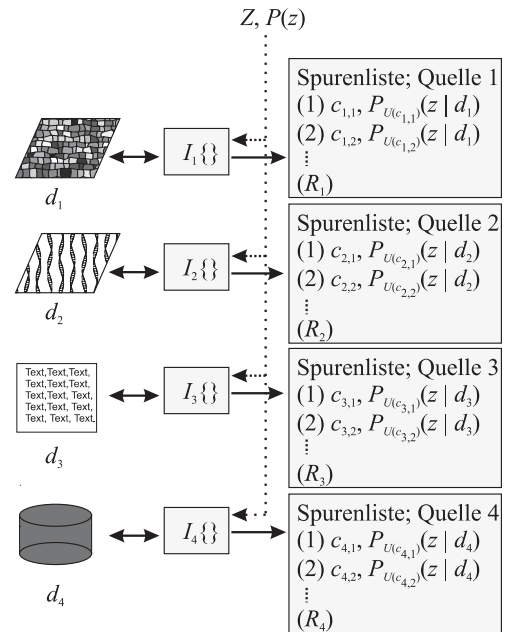


Bild 1: Initialisierungsphase. Quellspezifische Operatoren liefern Spuren, die in Spurenlisten gespeichert und nach Abschluss der Initialisierung an Fusionsagenten zugewiesen werden.

Figure 1: Initialization: Source specific operators deliver clues that are stored in hit lists. If the initialization has been finished, the clues are given to fusion agents.

werden in einer Spurenliste gesammelt und nach Signifikanz geordnet. Formal wird jede Spur durch das Paar $(c_{s,r}, P_{U(c_{s,r})}(z|d_s))$ repräsentiert, mit $r \in \{1, \dots, R_s\}$, $s \in \{1, \dots, S\}$ und

$P_{U(c_{s,r})}(z|d_s)$: lokale DoB-Verteilung; berechnet durch lokale Normierung von $i(z|d_s)$

R_s : Zahl signifikanter Spuren in d_s

$C = \sum_{s=1}^S R_s$: Gesamtzahl der Spuren aller Quellen

Für jede Spur wird ein Fusionsagent (FA) instantiiert; siehe Bild 1.

4.3.1 Lokale DoB-Verteilungen

Die entscheidende Idee zur Minderung der Komplexität der Bayes'schen Fusion ist, jedes $c_{s,r} \in Z$, das im Hinblick auf die gestellte Aufgabe hinreichend auffällig ist, lokal innerhalb einer Umgebung $U(c_{s,r}) \subset Z$ zu beschreiben, die ausreichend groß sein muss, um darin Bayes'sche Fusion betreiben zu können.

Für intervall- und verhältnisskalierte Größen kann $U(c)$ z. B. mittels einer Norm $\|\cdot\|$ definiert werden:

$$U(c) := \{z \mid \|z - c\| < \epsilon\}.$$

Bei qualitativen „Größen“ ergibt ein solches Konzept von Nachbarschaft allenfalls für ordinal skalierte Größen einen gewissen Sinn. Im nominalen Fall bedarf Lokalität einer speziell angepassten Definition, die am Beispiel einer einkomponentigen Eigenschaft z erläutert wird:

Es sei $Z^* \subset Z$ die Teilmenge von Elementen aus Z , deren DoBs einen bestimmten Mindestwert überschreiten. Eine Art Lokalität kann nun eingeführt werden, indem man nur für die $z \in Z^*$ detaillierte DoBs ausweist und einen pauschalen DoB für $Z \setminus Z^*$:

$$P_{U(c)}(z|d) := \begin{cases} P(z|d), & z \in Z^*, \\ P(Z \setminus Z^*|d) = 1 - \sum_{\zeta \in Z^*} P(\zeta|d), & z \notin Z^*. \end{cases} \quad (4)$$

Ein Beispiel soll diese Idee illustrieren: Es sei die Aufgabe, Automobile in einem Luftbild d_s zu klassifizieren. Ein „lokales“ Ergebnis könnte dann z. B. so aussehen:

$$\begin{aligned} P(z = \text{VW_Golf} | d_s) &= 0,8, \\ P(z = \text{Ford_Focus} | d_s) &= 0,15, \\ P(z = \text{anderer_Typ} | d_s) &= 0,05. \end{aligned}$$

Anstatt für wahrscheinlich über tausend Fahrzeugtypen eine detaillierte Verteilung anzugeben, werden mit dem lokalen Ansatz nur drei Werte zur Beschreibung des DoB für die nominale Eigenschaft Typ kommuniziert.

Das Konzept lokaler DoB-Verteilungen bietet neben der unmittelbaren Komplexitätsminderung der Bayes'schen Inferenz von $O(|Z|)$ auf $O(C|U|)$ einen weiteren Vorteil: Während bei globaler Betrachtung die *A-posteriori*-DoB-Verteilung auf Z i. d. R. eine komplizierte multimodale Gestalt haben wird, ist die Struktur lokaler DoB-Verteilungen einfacher und kann mit simpleren Verteilungsmodellen beschrieben oder zumindest approximiert werden.

4.3.2 Lokale Fusion

Nachdem jeder Spur ein FA zugewiesen wurde, besuchen die FAs in Bezug auf ihre Spuren bisher nicht berücksichtigte Quellen, um ihre lokalen DoB-Verteilungen weiterzuentwickeln; siehe Bild 2. Falls ein FA nicht selbst fähig ist, auf eine Quelle s zuzugreifen oder deren Daten auszuwerten, konsultiert er einen Experten-Agenten ($\hat{=}$ Sachverständigen), dem er die bis dahin entwickelte Spur übergibt.

Der Experte fasst die ihm überlassene lokale DoB-Verteilung als *A-priori*-Verteilung auf, die er anhand der ihm vorliegenden Daten d_s mittels der Bayes'schen

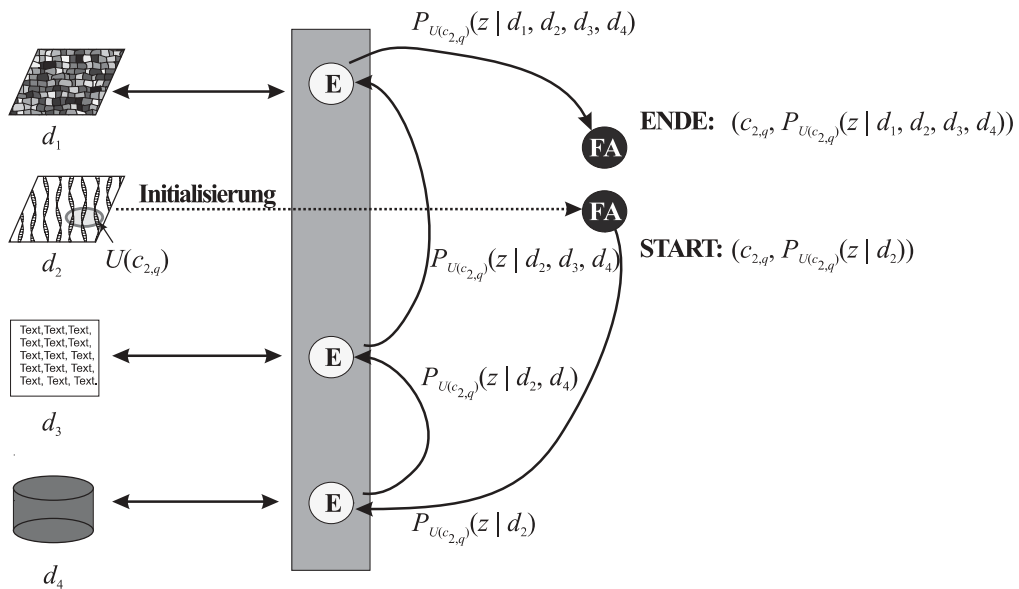


Bild 2: Jede Spur wird von einem Fusionsagenten (FA) verfolgt, der die Hilfe von Experten (E) in Anspruch nehmen kann. Dargestellt ist hier der für die Spur $c_{2,q}$ zuständige FA. Die Ellipse in d_2 illustriert die Umgebung U der Spur $c_{2,q}$ in Bezug auf zwei Komponenten von z ; in diesem Beispiel sind es zwei Ortskoordinaten.

Figure 2: Every trace is investigated by a fusion agent who can consult experts. This picture illustrates the work of the fusion agent who is responsible for the clue $c_{2,q}$. The ellipse in d_2 indicates the local environment around $c_{2,q}$ with respect to two coordinates of z ; these are here the spatial coordinates.

Formel in eine lokale *A-posteriori*-DoB-Verteilung überführt und so lokale Fusion vollzieht. Danach gibt der Experte die Spur an den FA zurück, der dann die nächste Quelle aufsucht.

Zu den Aufgaben eines FAs gehört die Verwaltung seiner Spur, das Aufsuchen der verfügbaren Quellen aber auch gelegentlich mit anderen FAs zu kommunizieren, um herauszufinden, ob Spuren anderer FAs nicht das gleiche reale Objekt oder Ereignis zugrunde liegt, sodass schließlich überflüssige FAs eliminiert werden können. Dieser Fall tritt ein, wenn für reale Objekte oder Ereignisse mehrere Quellen initial signifikante Spuren liefern. Bei der Initialisierung muss zunächst für jede signifikante Spur ein FA instantiiert werden, um Objekte und Ereignisse nicht zu verpassen, für die nur eine Quelle initial signifikante Spuren liefert.

Hat ein FA alle Quellen besucht, liefert er seine nunmehr elaborierte Spur einer „Jury“ ab, die dann in der Zusammenschau aller Spuren und der damit einhergehenden Hypothesen über deren globale Signifikanz entscheiden kann.

4.3.3 Diskussion

Das Konzept der FAs hat eine intrinsische Skalierbarkeit. Anhand zur Verfügung stehender Ressourcen kann über die Zahl $A \leq C$ der zu instanziierten FAs entschieden werden, sodass zumindest die wichtigsten Spuren (heiße Spuren) verfolgt werden können.

Ein Vorteil des Ansatzes ist auch die Möglichkeit, die „Untersuchungen“ teilweise technisch und teilweise durch Menschen auszuführen. Insbesondere wenn für einen Teil der Quellen bisher keine ausreichend leistungsfähigen Auswertautomatismen existieren und man auf den Verstand und die kognitiven Fähigkeiten des Menschen angewiesen ist, sind solche Mensch-Maschine-Teams sinnvoll. Mit fortschreitender Entwicklung können dann solche Teams durch Hinzufügen neuer softwarebasierter Experten erweitert und durch Substitution der menschlichen Experten weiter automatisiert werden.

Unmittelbar leuchtet auch ein, dass das gezeigte Konzept für Fusionsaufgaben in großen Netzwerken mit verteilten Informationsquellen prädestiniert ist.

4.4 Beispiel

Durch die Fusion von *A-priori*-Wissen, HUMINT- (Human Intelligence: Information von Menschen) und IMINT- (Image Intelligence: Bilddaten) Information sollen aus einer vorgegebenen Szene Position und Typ der dort vorhandenen Fahrzeuge bestimmt werden; siehe Bild 3. Der Raum des Interesses ist gegeben durch

$$Z = [x_{\min} = 0 \text{ cm}, \quad x_{\max} = 94 \text{ cm}] \\ \times [y_{\min} = 0 \text{ cm}, \quad y_{\max} = 50,3 \text{ cm}] \times \{\text{Fahrzeugtypen}\}$$

Die Menge der möglichen Fahrzeugtypen wurde im Beispiel der Übersichtlichkeit halber auf die fünf Typen *Ford*, *Audi*, *Chevrolet*, *BMW* und *Mercedes* eingeschränkt.

Die Kenntnis einer *a priori* vorliegenden Straßenkarte der Szene ist in der vorliegenden Aufgabenstellung äquivalent zur Kenntnis der Menge

$$S = \{(x, y) | ((x, y) \text{ ist Punkt der Szene}) \\ \wedge ((x, y) \text{ ist Punkt einer Straße})\},$$

durch die die Punkte der Szene, die auf einer der Straßen liegen und demzufolge die einzig möglichen Fahrzeugpositionen darstellen, spezifiziert werden. Die *ME-a-priori*-DoB-Verteilung $P_{ME(S)}$ sei die Gleichverteilung $P_{GV(S)}$ auf S . Geht man nun außerdem von einer Messunsicherheit σ_ξ für jeden Punkt (x, y) in der Straßenkarte aus, so ist die *ME-a-priori*-Verteilung $P_{ME(S, \sigma_\xi)}$, die zusätzlich noch dieses Faktum berücksichtigt, näherungsweise die Faltung der Gleichverteilung auf S mit der zweidimensionalen Normalverteilung $N(0, I\sigma_\xi^2)$. Dies kann man sich für jeden Punkt x wie folgt veranschaulichen (vgl. Abschnitt 3.3):

$$P_{ME(S, \sigma_\xi)}(x, y) = P_{ME(S, \sigma_\xi)}((x - \xi) + \xi, (y - \eta) + \eta) \\ \approx P_{ME(\sigma_\xi)}(x - \xi, y - \eta) * P_{ME(S)}(\xi, \eta) \\ = N(0, I\sigma_\xi^2) * P_{GV(S)}(\xi, \eta) \\ = \iint_{(\xi, \eta) \in S} N((x - \xi, y - \eta), I\sigma_\xi^2) d\xi d\eta.$$

Bild 3A zeigt die so resultierende *ME-a-priori*-Verteilung für $\sigma_\xi = 0,5 \text{ cm}$.

Quelle $s = 1$ liefert ein Grauwertbild d_1 ; siehe Bild Fig. 3B. Die von Quelle $s = 2$ gelieferte Information ist die verbale Beschreibung der Szene (HUMINT) im Hinblick auf die Detektion und Klassifikation von Fahrzeugen.

Zur Erzeugung von $i(z|d_1)$ wird eine an die gesuchten Fahrzeugtypen angepasste Matched-Filter-Bank verwendet. Die HUMINT-Information wird als Fakten und Messunsicherheiten in Bezug auf den Ort und mit einer Verteilung gemäß (4) im Bezug auf den Typ festgelegt. Für die beiden Ortskoordinaten resultiert als *ME*-Verteilung eine Gaußverteilung.

Das Ergebnis (Bild 3H) zeigt die bezüglich y marginalisierte DoB-Verteilung als Fusionsresultat für die in Bild 3D gezeigte Spur. Das Ergebnis beweist, dass die lokale Bayes'sche Fusion brauchbare Ergebnisse bei erheblich verringertem Rechenaufwand liefert. Nebenbei erkennt man hier, dass die beiden Quellen sich ergänzende Informationen liefern. So bestimmt d_1 im Wesentlichen den Ort des Fahrzeugs, d_2 dominiert die Schätzung des Typs.

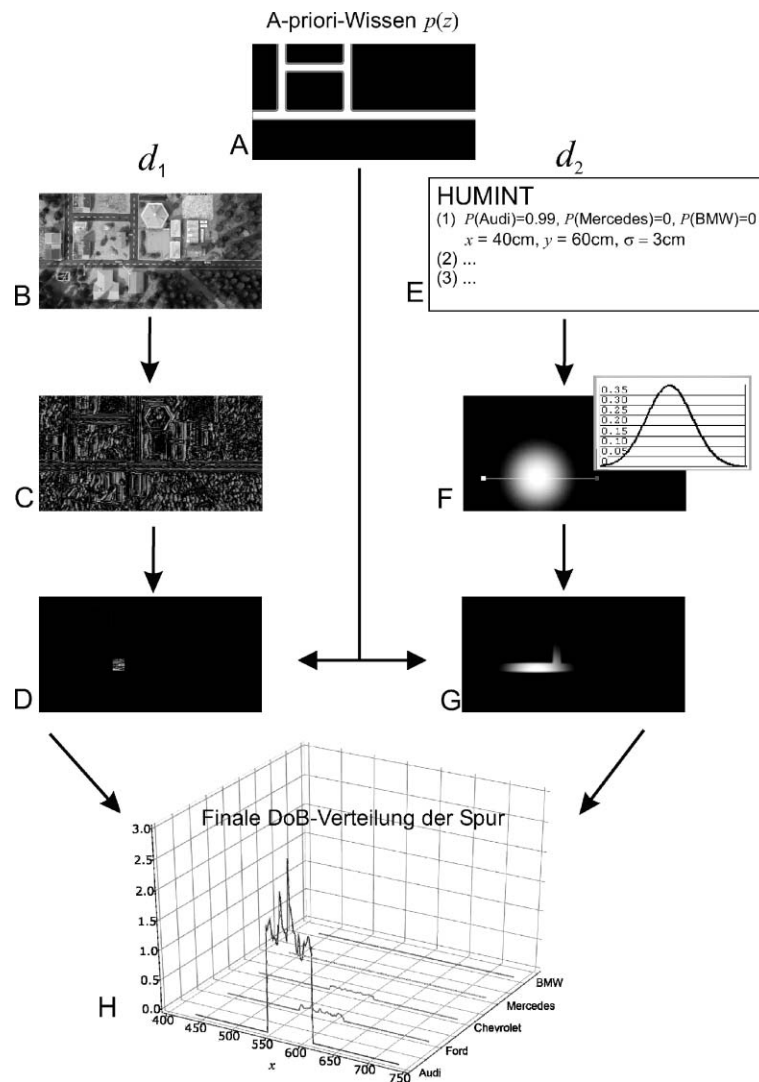


Bild 3: Das hier gezeigte illustrative Beispiel verwendet eine IMINT- und eine HUMINT-Quelle sowie eine Karte als *A-priori*-Wissen. Bei dem Beispiel handelt es sich um ein Landschaftsmodell im Maßstab 1 : 160. Der nominale Peak befindet sich bei *Audi*, was auch den Tatsachen entspricht. Dass für *BMW* und *Mercedes* die DoB-Verteilung null ist, liegt an der Einschätzung des menschlichen Beobachters, der die beiden Typen vollständig ausschloss.

Figure 3: This example deals with a landscape model (1 : 160). Information from an IMINT and a HUMINT source is fused with prior knowledge from a road map. The nominal peak is correctly at type *Audi*. The DoB-distribution is zero for the types *BMW* and *Mercedes* because of the estimation of the human observer who eliminated any possibility of these types completely.

5 Zusammenfassung und Ausblick

An eine Methodik für die Fusion heterogener Informationsquellen werden die drei Basisanforderungen nach Transformation, Fusion und Fokussierung gestellt. Die Bayes'sche Wahrscheinlichkeitstheorie in einer Degree-of-Belief-Deutung des Wahrscheinlichkeitsbegriffes ist

eine geeignete Fusionsmethode, die diese Anforderungen erfüllt. Allerdings wächst der Rechenaufwand der Bayes'schen Methodik exponentiell mit der Zahl der interessierenden Größen und Eigenschaften.

Zur Bewältigung dieses Problems wird ein lokales Bayes'sches Fusionsverfahren eingeführt, das sich an kriminalistische Ermittlungen anlehnt, wo zu verfolgende Spuren zunächst nur in einem lokalen Kontext, eingebettet im Raum der interessierenden Größen, be-

trachtet werden. Aufgrund seiner Struktur lässt sich der Ansatz mit einer agentenorientierten Architektur zwanglos umsetzen, bei der die Fusionsagenten signifikante Spuren zugewiesen bekommen und der Fusionsprozess lokal durch sequenziellen „Besuch“ der verfügbaren Quellen erfolgt.

Zukünftige Forschungsaktivitäten werden sich der minimalen Größe von Umgebungen widmen, in der eine lokale Bayes'sche Fusion noch sinnvolle Ergebnisse liefert. Wichtig ist auch die Frage nach dem Umgang mit unterschiedlichen Quellen, deren gegenseitige statistische Abhängigkeit *a priori* nicht bekannt ist. Für die Beschreibung der lokalen DoB-Verteilungen soll untersucht werden, inwieweit das Konzept der konjugierten *A-priori*-Verteilungen umgesetzt werden kann; im Erfolgsfall könnte die lokale Fusion dann vereinfacht anhand algebraischer Verknüpfungen von Verteilungsparametern durchgeführt werden.

Während in diesem Aufsatz von *a priori* bekannten Quellen ausgegangen wurde, liegt eine explorative Verallgemeinerung nahe, die Fusionsagenten auch nach unbekanntem, für die Fusion relevanten Quellen suchen zu lassen, den Fusionsagenten also auch Recherche- und Data-Mining-Aufgaben zu übertragen.

Literatur

- [1] J. Beyerer, M. Heizmann, J. Sander: Fuselets – An Agent-Based Architecture for Fusion of Information of Heterogeneous Information and Data. In: Multisensor, Multisource Information Fusion: Architectures, Algorithms, and Applications 2006, Belur V. Dasarathy (Hrsg.), Proceedings of SPIE 6242, pp. 235–243.
- [2] J. O. Berger: Statistical Decision Theory and Bayesian Analysis. 2. Aufl., Springer, 1985.
- [3] J. M. Bernardo, A. Smith: Bayesian Theory. 1. Aufl., Wiley, 1994.
- [4] M. Berthold, D. J. Hand: Intelligent Data Analysis. 2. Aufl., Springer, 2003.
- [5] J. D. Hey: Data in Doubt – An Introduction to Bayesian Statistical Inference for Economists. 1. Aufl., Martin Robertson, 1983.
- [6] E. T. Jaynes: Information Theory and Statistical Mechanics. In: Phys. Rev., Part I: 106, S. 620–630, 1957. Part II: 108, S. 171–191, 1957.
- [7] E. T. Jaynes: Prior Probabilities. In: IEEE Transactions on Systems, Science, and Cybernetics, 4, Nr. 3, S. 227–241, 1968.
- [8] J. N. Kapur: Maximum Entropy Models in Science and Engineering. Revised ed., Wiley, 1993.
- [9] C. P. Robert: The Bayesian Choice. Springer, 1994.
- [10] S. J. Russell, P. Norvig: Artificial intelligence: A modern approach. Prentice Hall, 2003.
- [11] J. Sander, J. Beyerer: Fusion agents – realizing Bayesian fusion via a local approach. In: Proceedings of the 2006 IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems 2006 (MFI06), pp. 249–254, Heidelberg.
- [12] P. N. Tan, M. Steinbach, V. Kumar: Introduction to Data Mining. Addison-Wesley, 2006.
- [13] G. Winkler: Stochastische Systeme – Analyse und Synthese. Akademische Verlagsgesellschaft, Wiesbaden 1977.



1 Prof. Dr.-Ing. Jürgen Beyerer ist Leiter des Fraunhofer-Instituts IITB und Inhaber des Lehrstuhls für Interaktive Echtzeitsysteme an der Fakultät für Informatik, Universität Karlsruhe (TH).

Hauptarbeitsgebiete: Automatische Sichtprüfung und Bildverarbeitung, Fusion heterogener Informationsquellen, Informationstheorie, Systemtheorie, Statistische Verfahren, Messtechnik.

Adresse: Fraunhofer-Institut für Informations- und Datenverarbeitung, Fraunhoferstr. 1, 76131 Karlsruhe, E-Mail: juergen.beyerer@iitb.fraunhofer.de

2 Dipl.-Math. Jennifer Sander ist wissenschaftliche Angestellte am Lehrstuhl für Interaktive Echtzeitsysteme, Fakultät für Informatik, Universität Karlsruhe (TH).

Hauptarbeitsgebiete: Lokale Ansätze zur Informationsfusion, Bayes'sche Theorie.

Adresse: Institut für Technische Informatik, Universität Karlsruhe (TH), Adenauerring 4, 76131 Karlsruhe, E-Mail: jsander@ies.uni-karlsruhe.de

3 Dipl.-Ing. Stefan Werling ist wissenschaftlicher Angestellter am Lehrstuhl für Interaktive Echtzeitsysteme, Fakultät für Informatik, Universität Karlsruhe (TH).

Hauptarbeitsgebiete: Informationsgewinnung aus multidimensionalen Bildserien, Deflektometrie, 3D-Rekonstruktion.

Adresse: Institut für Technische Informatik, Universität Karlsruhe (TH), Adenauerring 4, 76131 Karlsruhe, E-Mail: werling@ies.uni-karlsruhe.de