

Modelo de Fusão de Dados com Incerteza para Consciência Situacional

Munye Mittelmann¹, Jerusa Marchi², Aldo von Wangenheim¹

¹Programa de Pós-Graduação em Ciência da Computação
Departamento de Informática e Estatística
Universidade Federal de Santa Catarina (UFSC)
Florianópolis – SC – Brazil

²Departamento de Informática e Estatística
Universidade Federal de Santa Catarina (UFSC)
Florianópolis – SC – Brazil

mmittelmann@incod.ufsc.br, {jerusa.marchi, aldo.vw}@ufsc.br

Abstract. *Situation Awareness provides a theory for agents decision making in order to allow perception and comprehension of his environment. However, transformation of sensory stimulus in beliefs in order to favor the BDI reasoning cycle is still an unexplored subject. This paper presents a model to beliefs generation using fuzzy-bayesian inference. An example in robotics navigation and location is used to illustrate the proposal.*

Resumo. *A área de Consciência Situacional provê uma teoria que embasa a tomada de decisão em agentes, de forma a permitir a percepção e a compreensão do ambiente em que o agente está inserido. Contudo, a transformação de estímulos sensoriais em crenças que favoreçam o ciclo de raciocínio em agentes BDI ainda é uma área pouco explorada. Este trabalho apresenta um modelo para geração de crenças, utilizando inferência Fuzzy-Bayesiana. Para ilustrar a proposta, um exemplo em navegação e localização robótica é utilizado.*

1. Introdução

Na área de psicologia cognitiva, a avaliação da situação atual é considerada como um aspecto cognitivo necessário para que haja uma tomada de decisão efetiva [Wickens and Hollands 2000]. Neste sentido, a Consciência Situacional (*Situation Awareness - SA*) é definida como a percepção dos elementos no ambiente dentro de um volume espaço-temporal e a compreensão de seus significados e de sua projeção num futuro próximo [Endsley 1995].

Endsley [Endsley 1995] define um modelo de SA que incorpora três diferentes níveis de consciência: (i) a percepção de sinais, (ii) a compreensão e integração da informação e (iii) a projeção da informação em eventos futuros. Embora a abordagem original seja referente a SA humana, o modelo também é utilizado como uma justificativa para estruturar o processo computacional de consciência situacional [Kokar et al. 2009]. A diferença entre o processo de consciência situacional humano e o computacional é que o processo humano precisa ser medido e possivelmente suportado, enquanto que o processo computacional precisa ser definido e implementado [Kokar et al. 2009].

O primeiro nível de SA é a Percepção e envolve perceber os sinais referentes aos atributos e dinâmicas de elementos relevantes no ambiente. O procedimento de coleta e monitoramento de dados situacionais varia dependendo das particularidades do cenário de aplicação, podendo incluir redes de sensores, dispositivos e atuadores [Chen et al. 2009].

O nível intermediário de SA é a Compreensão, que é responsável por integrar e compreender o significado das informações percebidas, sendo composto pela agregação de situações (associação), medição das propriedades das situações (avaliação), estimativa de situações (inferência) e medições de capacidade, oportunidade e intenção da situação (avaliação de impacto) [Golestan et al. 2016].

Por fim, o nível de Projeção é responsável por projetar a informação percebida e compreendida em situações futuras. Trabalhos na área de agentes autônomos costumam utilizar a projeção para a tomada de decisão e planejamento do agente [Insaurralde and Petillot 2015].

Agentes autônomos usualmente fazem uso de múltiplos sensores para possibilitar a captura de diferentes aspectos do ambiente. Nestes casos, é necessário que o agente tenha a capacidade de realizar um processo conhecido como fusão de dados, que inclui a fusão dos dados de baixo nível produzidos por sensores físicos, o reconhecimento de entidades relacionadas ao contexto para formar uma figura unificada do ambiente e identificação das correlações existentes entre entidades e situações [Golestan et al. 2016, Steinberg and Bowman 2004].

A pesquisa na área de Fusão de Informação fraciona o processo de fusão de dados sensoriais em quatro níveis funcionais, que são detalhados na Seção 2.1 [White 1988, Steinberg and Bowman 2004]. Os níveis de fusão de dados podem ser relacionados aos níveis de SA propostos por Endsley [Endsley 1995], uma vez que a fusão de dados de baixo nível é inerente ao nível de Percepção do agente e o produto do processo de fusão de dados de alto nível corresponde a ter alcançado a Consciência Situacional do agente [Golestan et al. 2016].

Ao nível de Percepção, os dados capturados por sensores físicos normalmente são afetados por algum nível de imprecisão ou incerteza em suas medidas. Tratar a incerteza proveniente de dados sensoriais é um dos desafios que impulsionam a pesquisa em fusão de dados [Khaleghi et al. 2013]. Dependendo da natureza da incerteza presente nos dados, diferentes métodos podem ser aplicados. Para tratar simultaneamente a incerteza por aleatoriedade e por vagueza, pode-se empregar a inferência *Fuzzy*-Bayesiana.

Neste trabalho, a inferência *Fuzzy*-Bayesiana é integrada a um modelo de fusão de dados com o objetivo de prover o nível de Percepção na Consciência Situacional de um agente. As percepções do agente são representadas por um conjunto de crenças, gerado como saída do modelo. As crenças de Percepção possuem grau de certeza e são propagadas para os níveis de Compreensão e Projeção.

O trabalho está estruturado como segue: na Seção 2 são apresentados os conceitos referentes aos níveis Funcionais de Fusão de Dados e a descrição da inferência *Fuzzy*-Bayesiana; na Seção 3 é apresentada a proposta de modelo paralelamente a um cenário exemplificando sua aplicação; a Seção 4 apresenta a implementação do exemplo em Jason; por fim, na Seção 5 são apresentadas algumas considerações da pesquisa.

2. Conceitos Básicos

Apresenta-se nesta seção a distinção entre os níveis de fusão de dados e sua relação com os níveis de SA de Endsley [Endsley 1995], e posteriormente, descreve-se a inferência *Fuzzy*-Bayesiana empregada nesta pesquisa dentro de um modelo de fusão de dados.

2.1. Níveis Funcionais de Fusão de Dados

A classificação mais comum do processo de fusão de dados é o modelo JDL proposto por White [White 1988] que considera o processo de fusão em quatro níveis crescentes de abstração: Objeto, Situação, Impacto e Refinamento do Processo.

Como extensão do modelo JDL, Steinberg e Bowman [Steinberg and Bowman 2004] apresentam os níveis Funcionais de Fusão de Dados (FFD). Neste particionamento, uma entidade de interesse do sistema pode ser vista como (i) um indivíduo com atributos, características e comportamentos ou (ii) como um conjunto de componentes inter-relacionados. Os níveis FFD de Steinberg e Bowman [Steinberg and Bowman 2004] são definidos conforme segue:

- (0-FFD) Avaliação de Sinais: estimacão e predicão de sinais ou estados característicos;
- (1-FFD) Avaliação de Entidades: estimacão e predicão de parametrizacão de entidade e estados atributivos;
- (2-FFD) Avaliação de Situações: estimacão e predicão das estruturas de partes da realidade, como relacão entre entidades e suas implicações nos estados de entidades relacionadas;
- (3-FFD) Avaliação de Impacto: estimacão e predicão do custo/benefício do sinal, entidade ou estados de situações;
- (4-FFD) Avaliação de Desempenho: estimacão e predicão do desempenho do sistema quando comparado aos estados desejados e medidas de efetividade.

A fusão de dados de baixo nível corresponde aos níveis 0-FFD, 1-FFD e 2-FFD, os quais são responsáveis pela identificacão de entidades e suas correlações. Estes três níveis são análogos ao nível de Percepção de SA. O nível 2-FFD também inclui a estimacão da implicacão dos relacionamentos entre entidades em seus estados, podendo ser relacionado ao nível de Compreensão de SA. Os níveis 3-FFD e 4-FFD têm a função de prever custos, estados e desempenho do sistema, tendo correspondência, principalmente, com o nível de Projecão de SA.

Relacionamentos entre entidades no nível 2-FFD podem ter características implicacionais e são comumente modelados por meio de Modelos Gráficos Probabilísticos, como Redes Bayesianas, Redes Bayesianas Dinâmicas e Redes *Fuzzy*-Bayesianas [Koller and Friedman 2009, Golestan et al. 2016]. Com intuito de compreender a fusão de dados de baixo nível e o nível de Percepção de SA, este trabalho aplica inferência *Fuzzy*-Bayesiana em um modelo para agentes.

2.2. Inferência *Fuzzy*-Bayesiana

Conjuntos difusos são classes que possuem continuidade em seus graus de pertinência [Zadeh 1965]. Dados difusos usualmente não são descritos pela inferência Bayesiana padrão e, assim, é necessário modelá-los de modo a incorporar seu aspecto difuso antes de analisá-los por métodos estatísticos [Viertl 1987, Viertl 2008]. Os estudos de Viertl

[Viertl 1987, Viertl 1989, Viertl and Hule 1991, Viertl 1995, Viertl 2008], investigam a generalização da estatística Bayesiana para dados difusos, tais abordagens híbridas são conhecidas como inferências *Fuzzy*-Bayesianas.

Dentre as inferências *Fuzzy*-Bayesianas existentes, o modelo apresentado em [Brignoli et al. 2015] é uma extensão que visa incluir variáveis difusas não-dicotômicas¹. O modelo de inferência Bayesiana com entradas difusas proposto é baseado na superposição de estados. Brignoli et al. [Brignoli et al. 2015] define a probabilidade \tilde{P} sobre evidências imprecisas, conforme a seguinte equação:

$$\tilde{P}(H_i|E_jx_k) = \frac{P(H_i) \times \prod_{j=1}^m \sum_{k=1}^t (P(E_jx_k|H_i) \times (\varepsilon E_jx_k))}{\sum_{l=1}^n P(H_l) \times \prod_{j=1}^m \sum_{k=1}^t (P(E_jx_k|H_l) \times (\varepsilon E_jx_k))} \quad (1)$$

Na qual, H_i , com $1 \leq i \leq n$, é o vetor de n hipóteses; E_jx_k , com $1 \leq j \leq m$ e $1 \leq k \leq t$, é o vetor de m evidências E observadas nos estados x contínuos; t é a quantidade de estados; $P(H_i)$ é a probabilidade a priori sobre H_i ; $P(E_jx_k|H_i)$ é a probabilidade condicional de E_jx_k dado H_i ; e εE_jx_k representa o estado x_k da evidência E_j em relação a função de pertinência difusa. Assim, $\tilde{P}(H_i|E_jx_k)$ é o vetor das probabilidades de H_i ajustadas pela imprecisão sobre as variáveis E_j de estados contínuos x_k .

O modelo de inferência *Fuzzy*-Bayesiana de [Brignoli et al. 2015] é empregado nesta proposta. A inferência *Fuzzy*-Bayesiana é utilizada para tratar a incerteza por vagueza presente nas entidades observadas e para modelar os relacionamentos probabilísticos entre entidades.

3. Proposta

O trabalho propõe um modelo de Fusão de Dados com Incerteza para atingir a Consciência Situacional de um agente ao nível de Percepção. O modelo abrange os níveis de fusão de dados 0-FFD, 1-FFD e 2-FFD. Para esclarecer a proposta, é introduzido um cenário de exemplo na Seção 3.1. O cenário de exemplo é acompanhado em paralelo ao detalhamento da proposta. A Figura 1 introduz uma visão geral do modelo de Fusão de Dados, ilustrando sua relação com os modelos de SA e FFD.

No nível 0-FFD, é realizada a captura das medições sensoriais, são definidas as estruturas dos conjuntos de medição, mas não são tratadas suas semânticas. O nível 1-FFD é responsável pela estimação de entidades e classificações. As entidades são agregadas e consideradas como observações, em seguida, são classificadas em relação a sua pertinência a conjuntos *fuzzy* do domínio.

O nível 2-FFD diz respeito as relações entre entidades e suas implicações. A implicação entre as entidades é realizada por meio da inferência Bayesiana com as entradas difusas do nível predecessor. Com base nos resultados da inferência, o modelo gera crenças, com grau de certeza, sobre a situação observada. Neste modelo, os níveis 0-FFD, 1-FFD e 2-FFD representam o nível de Percepção de SA. As crenças geradas pelo modelo são disponibilizadas para serem utilizadas nos níveis de Compreensão e Projeção de SA. Os estágios do modelo são especificadas nas Seções 3.2, 3.3 e 3.4.

¹Considera-se como variável dicotômica aquela que é dividida logicamente em apenas dois conceitos, geralmente opostos.

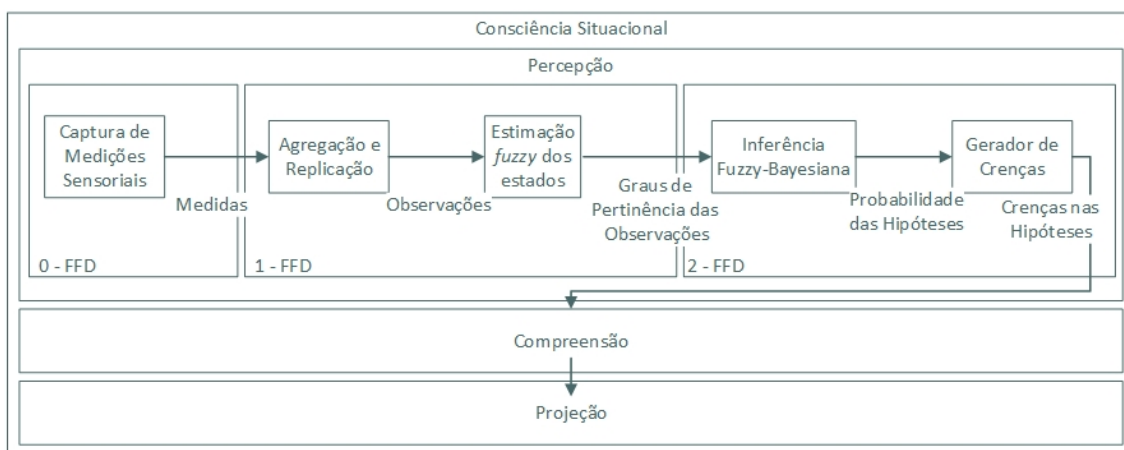


Figura 1. Modelo de Fusão de Dados para Consciência Situacional

3.1. Exemplo de Cenário de Aplicação

Considere a existência de um robô cujo objetivo é limpar os cômodos de uma casa. Como cada cômodo demanda equipamentos de limpeza distintos, o robô precisa saber em qual cômodo está. A casa é composta por dois quartos (Q_1 e Q_2 , respectivamente) e dois corredores conectando os quartos (C_1 e C_2 , respectivamente). A Figura 2(a), ilustra a distribuição dos cômodos Q_1 , Q_2 , C_1 e C_2 pela casa.

O robô caminha aleatoriamente pela casa e não conhece a disposição de seus cômodos. Para perceber o ambiente, o robô possui apenas sensores para captar sons, luminosidade e distância. Com estes sensores, o robô precisa descobrir, respectivamente, se a sonorização do ambiente é alta ou baixa (Figura 2(b)), se o ambiente está claro ou escuro (Figura 2(c)) e se o espaço entre as paredes é amplo ou apertado (Figura 2(d)). Observa-se que as informações sensoriais são classificadas por variáveis linguísticas providas de imprecisão por vagueza (alto e baixo, claro e escuro, amplo e apertado).

Antes de ser posto em funcionamento, o robô recebeu informações amostrais sobre mapeamentos anteriores do ambiente. Assim, ele conhece a probabilidade *a priori* de estar em cada cômodo, bem como as probabilidades condicionais de estar com sonorização alta ou baixa, em um ambiente claro ou escuro e em um espaço amplo ou apertado dado que está em algum cômodo específico. As Figuras 2(b), 2(c) e 2(d) ilustram, respectivamente, a distribuição da sonorização, iluminação e espaço pela casa em um determinado momento. Os valores das medições de som, luminosidade e distância podem variar dependendo do momento, seja por causa de falha sensorial ou de mudança no ambiente.

Munido apenas das informações sensoriais e das probabilidades *a priori* e condicionais, o robô deve decidir em qual cômodo está e, assim, ser capaz de determinar seus planos de ação. Durante a apresentação da proposta, o cenário do Robô Limpador é retomado de modo a exemplificar a aplicação e os níveis do modelo. A proposta é apresentada em três estágios, correspondentes aos níveis FFD abrangidos pelo modelo.

3.2. Nível de Avaliação de Sinais (0-FFD)

No nível 0-FFD, é realizada a estimção de sinais ou medições. O Agente possui um conjunto $\mathcal{S}_T = \{S_{T_1}, \dots, S_{T_n}\}$ de sensores, onde T_i representa o tipo de sensor e $S_{T_i} =$

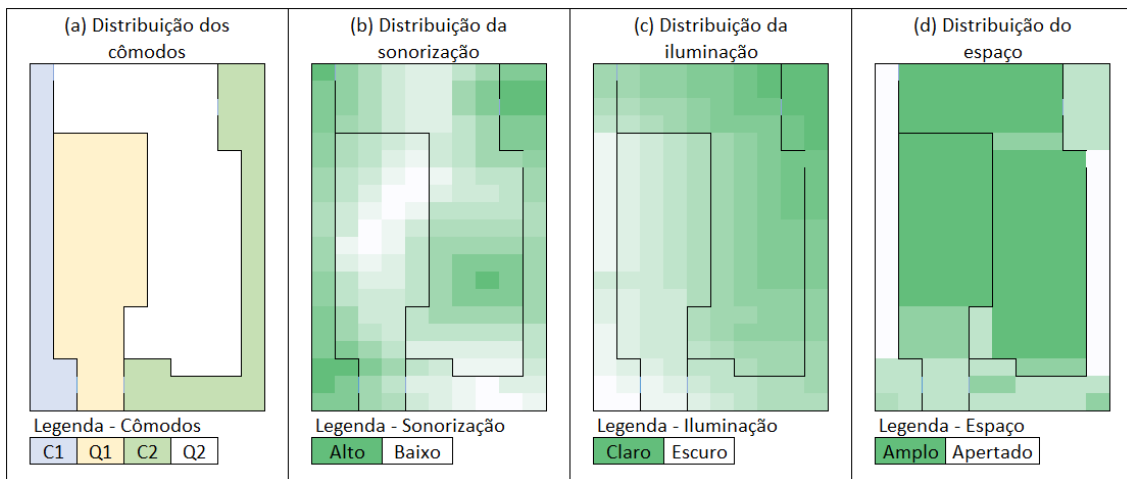


Figura 2. Cenário do Robô Limpador

$\{s_1, \dots, s_m\}$ representa um conjunto de sensores físicos de mesmo tipo. Para cada S_{T_i} são obtidos conjuntos M_i de medidas, de forma que $\mathcal{M} = \bigcup_{i \in T} M_i$ forma o conjunto de todos os sinais percebidos pelo agente.

Exemplo 1 O Robô Limpador da Seção 3.1 possui três tipos de sensores: luminosidade, distância e sonoro, ou seja: $\mathcal{S}_{T_{robo}} = \{S_{luz}, S_{distancia}, S_{som}\}$. O robô possui um sensor de luminosidade, dois de distância e um sonoro, assim $S_{luz} = \{s_{luz}\}$, $S_{distancia} = \{s_{d1}, s_{d2}\}$, com s_{d1} e s_{d2} sendo, respectivamente, os sensores de distância à direita e à esquerda do robô, e $S_{som} = \{s_{som}\}$. As medidas obtidas pelos sensores são $\mathcal{M}_{robo} = \{m_{luz}, m_{d1}, m_{d2}, m_{som}\}$. A Figura 3 ilustra o nível de Avaliação de Sinais para o Robô Limpador.

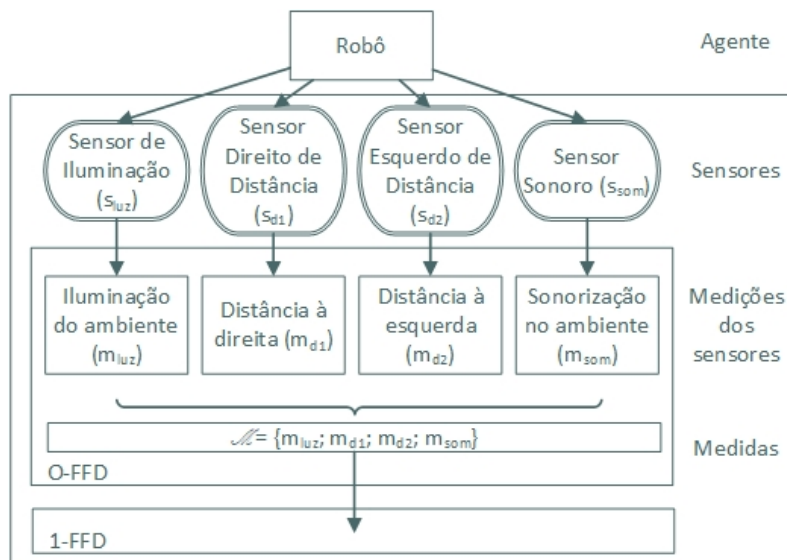


Figura 3. Nível de Avaliação de Sinais (0-FFD) no Cenário do Robô Limpador

3.3. Nível de Avaliação de Entidades (1-FFD)

O nível 1-FFD é responsável pela estimação de evidências e suas classificações. Neste estágio, ocorre a transformação dos dados de medidas em evidências observadas. A

transformação das medidas é definida como a aplicação de uma função $f(x) \rightarrow \mathbb{R}$ sobre os mesmos, onde $f \in \{A, R\}$ é uma função de Agregação ou Replicação, $x \in 2^{\mathcal{M} \setminus \emptyset}$ ² é a aridade da função. Cada função $f(x)$ gera uma nova evidência observada $o_k \in \mathbb{R}$, na qual k representa um domínio (ex.: distância, iluminação, sonorização).

A função de Agregação A é realizada por meio de operações sobre uma ou mais as medições pertencentes a \mathcal{M} e é definida por $A(m_i, \dots, m_j) \rightarrow \mathbb{R}$, com $(m_i, \dots, m_j) \in 2^{\mathcal{M} \setminus \emptyset}$. A função de Replicação R realiza cópia de um elemento de \mathcal{M} , tal que $R(m_i) \rightarrow \mathbb{R}$, com $m_i \in \mathcal{M}$.

Sobre o_k é aplicado o operador de normalização, tal que $N : \mathbb{R} \rightarrow [0, 1]$. Tal operação visa facilitar o suporte de cada evidência observada, entretanto, não é necessário realizar a normalização. Para fins de simplificação da notação, continuaremos a denominar a evidência observada normalizada de o_k . Consideraremos $\mathcal{O} = \bigcup_{\forall k} o_k$ o conjunto global de evidências.

Exemplo 2 No cenário do Robô Limpador, as medições m_{d1} e m_{d2} são agregadas tal que $o_{\text{espaco}} = \| m_{d1} \| + \| m_{d2} \|$ ³. Ou seja, o espaço entre as paredes o_{espaco} é a soma da distância da parede à direita do robô com a distância da parede à esquerda do robô. As medições m_{luz} e m_{som} são replicadas como evidências observadas, tal que $o_{\text{luz}} = m_{\text{luz}}$ e $o_{\text{som}} = m_{\text{som}}$. Nota-se que $\mathcal{O}_{\text{robo}} = \{o_{\text{luz}}, o_{\text{espaco}}, o_{\text{som}}\}$ é o conjunto normalizado de todas as evidências observadas pelo robô.

Para cada evidência observada o_k é considerado um universo de discurso no intervalo $[min_k, max_k]$, denotado por \mathcal{A}_k , onde min_k e max_k , respectivamente, são os valores mínimos e máximos do domínio K . Para cada $o_k \in \mathcal{O}$ será calculado o valor de pertinência a algum conjunto fuzzy A_k , definido sobre $\mathcal{A}_k = \{A_{k1}, \dots, A_{kn}\}$. O grau de pertinência de o_k ao conjunto A_{k_i} é denotado por $\mu_{A_{k_i}}(o_k)$. O conjunto de todos os graus de pertinência $\mu_{A_{k_i}}(o_k)$, $\forall A_{k_i} \in \mathcal{A}_k$ e $\forall o_k \in \mathcal{O}$ é denotado por: $\mu(\mathcal{O}) = \bigcup_{\forall k, \forall i} \mu_{A_{k_i}}(o_k)$.

Exemplo 3 Para cada evidência observada pelo Robô Limpador, foi definido um universo de discurso e calculados os graus de pertinência da evidência a cada conjunto do universo de discurso. Para o_{luz} , $\mathcal{A}_{\text{luz}} = \{\text{claro}; \text{escuro}\}$. Para o_{espaco} , $\mathcal{A}_{\text{espaco}} = \{\text{amplo}; \text{apertado}\}$. Para o_{som} , $\mathcal{A}_{\text{som}} = \{\text{baixo}; \text{alto}\}$. A seguir, para cada evidência o_k observada pelo robô, foi estimado seu grau de pertinência $\mu_{A_{k_i}}(o_k)$ para cada conjunto $A_{k_i} \in \mathcal{A}_k$ (Figura 4).

3.4. Nível de Avaliação de Situação (2-FFD)

O nível 2-FFD é responsável por estimar as relações entre as evidências e suas implicações. Os graus de pertinência das observações $\forall \mu_{A_{k_i}}(o_k) \in \mu(\mathcal{O})$, são considerados como as evidências da inferência Fuzzy-Bayesiana. Sendo $\mathcal{H} = \{H_1, \dots, H_n\}$ o conjunto de hipóteses sobre Z , Z como a situação na qual o agente está, $P(H_h) \rightarrow [0; 1]$ representa a probabilidade a priori da h -ésima hipótese e $P(o_k|H_h) \rightarrow [0; 1]$ é a probabilidade de observar o_k dada a hipótese H_h . A probabilidade da hipótese H_h ajustada pela imprecisão sobre todas as observações $o_k \in \mathcal{O}$ é denotada por $\tilde{P}(H_h|\mathcal{O})$ e definida aplicando a Equação (1) às definições do modelo, tal que:

² $2^{\mathcal{M} \setminus \emptyset}$ representa o conjunto das partes de \mathcal{M} sem o conjunto vazio \emptyset .

³ $\| x \|$ representa o módulo de um número $x \in \mathbb{R}$.

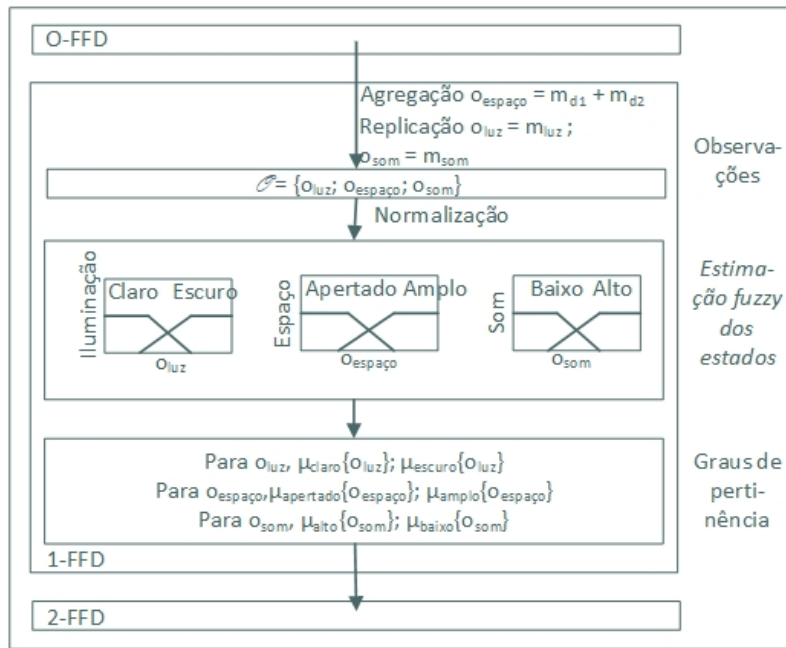


Figura 4. Nível de Avaliação de Entidades (1-FFD) no Cenário do Robô Limpador

$$\tilde{P}(H_h|\mathcal{O}) = \frac{P(H_h) \times \prod_{k=1}^{|\mathcal{O}|} \sum_{i=1}^n (P(o_k|H_h) \times \mu_{A_{k_i}}(o_k))}{\sum_{l=1}^{|H|} P(H_l) \times \prod_{k=1}^{|\mathcal{O}|} \sum_{i=1}^n (P(o_k|H_l) \times \mu_{A_{k_i}}(o_k))} \quad (2)$$

A probabilidade ajustada pela imprecisão $\tilde{P}(H_h|\mathcal{O})$ é estimada $\forall H_h \in \mathcal{H}$.

A situação avaliada no cenário da Seção 3.1 é a localização atual do robô, ou seja $Z_{robo} = Local$. As hipóteses são as possibilidades de localização, os cômodos da casa, então $\mathcal{H}_{robo} = \{H_{Q_1}; H_{Q_2}; H_{C_1}; H_{C_2}\}$. Assim, $P(H_h)$ representa as probabilidades a priori do robô estar em cada cômodo da casa. $P(o_k|H_h)$ são as probabilidades condicionais dos estados de uma observação, ou seja $o_k = luz, som$ ou $espaco$, sabendo-se que está em determinado cômodo (H_h).

Exemplo 4 Para o Robô Limpador, a inferência Fuzzy-Bayesiana descobre as probabilidades $\tilde{P}(H_h|\mathcal{O})$ de estar em cada cômodo $\forall H_h \in \mathcal{H}_{robo}$ dadas as evidências observadas pelo robô $\mathcal{O}_{robo} = \{o_{luz}, o_{espaco}, o_{som}\}$.

A última etapa do modelo é denominada Gerador de Crenças (GC). Considera-se que o conjunto de hipóteses \mathcal{H} seja formado pelas implicações das relações entre as observações, ou seja, a conclusão do que o agente está observando. Assim, para cada hipótese $H_h \in \mathcal{H}$, o GC gera uma crença em lógica de predicados na forma: $Z(H_h, G_h)$, onde, Z é o símbolo de predicado que representa a situação atual acreditada pelo agente e G_h é o grau de certeza do agente em relação a hipótese H_h , dado por $G_h = \tilde{P}(H_h|\mathcal{O})$.

Exemplo 5 Para cada cômodo da casa, o GC do Robô Limpador gera uma crença com o grau de certeza que o robô tem de estar no cômodo. A Figura 5 ilustra o nível de avaliação de situação no cenário do Robô Limpador.

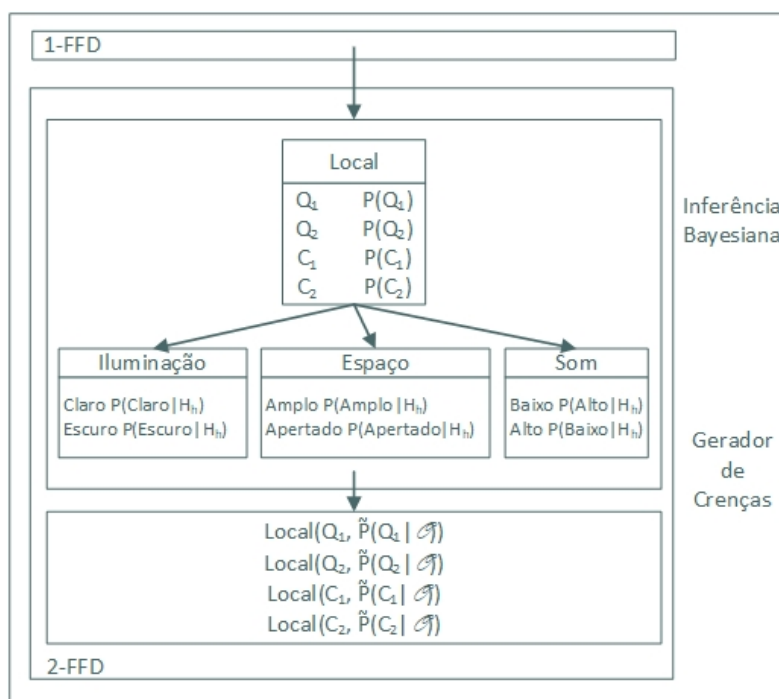


Figura 5. Nível de Avaliação de Situação (2-FFD) no Cenário do Robô Limpador

As crenças geradas pelo modelo são do nível de Percepção e possuem o propósito de fundamentar a integração de crenças distintas como crenças inferidas (nível de Compreensão) e sua projeção em crenças futuras (nível de Projeção). A obtenção de crenças situacionais aos níveis de Percepção, Compreensão e Projeção permite que o agente realize planejamento e tomada de decisão com base em sua situação atual. É intuitivo que o Agente deva considerar, durante a Compreensão e Projeção, a crença com maior grau de certeza. Entretanto, incluir as crenças para todas as hipóteses permite que o agente reaja a situações para as quais nenhuma crença tenha um grau de certeza razoável.

Exemplo 6 Considere um grau de certeza na crença C_1 de 51% e em C_2 de 49%. Estes valores indicam que o agente tem preferência em acreditar em C_1 . Entretanto, como a diferença do grau de certeza entre as crenças é baixa, existe grande incerteza em relação a situação. A propagação desta incerteza permite considerá-la nos planos do agente. Suponha que o agente deva realizar a ação A_1 quando está na situação descrita por H_1 . Ao invés de executar A_1 imediatamente, o agente pode reagir de acordo com a incerteza: esperar uma nova informação sensorial, consultar outro agente, entregar o controle da ação a um humano, etc.

4. Implementação do Robô Limpador

O exemplo explorado ao longo deste trabalho foi implementado em Jason⁴ com um agente BDI. A Figura 6 apresenta os planos do agente e a seguir é detalhado seu funcionamento.

Por questões de limitação de espaço, são omitidos os detalhes das funções (i) `limpar(Agente)`, (ii) `andar(Agente, Passos)`, (iii) `esperar(Agente, Tempo)`, (iv) `atualizarCrenças(Agente)`,

⁴Jason é um interpretador de AgentSpeak, disponível em <http://jason.sourceforge.net/>.

```

1 //Regra 1
2 sabe_local(roboto) :- local(_, X) & X >= 0.6.
3
4 // Meta inicial
5 !limparAmbiente(roboto).
6
7 //Plano 1
8 ⊕ !limparAmbiente(roboto): true
9 ⊕   <- !verificarLocal(roboto)
10 ⊕   limpar(roboto)
11   andar(roboto, 1).
12
13 //Plano 2
14 ⊕ !verificarLocal(roboto): true
15 ⊕   <- -local(_,_)
16   atualizarCrenças(roboto).
17
18 //Plano 3
19 ⊕ local(Comodo, Grau): Grau >= 0.6
20   <- selecionarMateriais(roboto, Comodo).
21
22 //Plano 4
23 ⊕ local(_, _): not sabe_local(roboto)
24 ⊕   <- esperar(roboto, 5)
25   !verificarLocal(roboto).

```

Figura 6. Base de Crenças e Planos do Robô Limpador

(v)selecionaMateriais(Agente, Comodo). Onde em (i) o Agente verifica se sua posição atual precisa ser limpa, neste caso, procede a limpeza; (ii) o Agente se locomove Passos posições; (iii) o Agente espera Tempo segundos; (iv) o Agente atualiza suas crenças conforme o modelo proposto que retorna o conjunto de crenças no formato `local(Comodo, Grau)`, ou seja, engloba o processo de obter as medições do ambiente, estimá-las como evidências *fuzzy* e gerar crenças com os graus de certezas obtidos por meio da Equação (2); (v) o Agente seleciona os materiais de limpeza adequados para o Comodo.

A Regra 1 (Figura 6 - linha 2) é verdadeira caso o robô acredite estar em determinado local com grau de certeza maior ou igual a 0,6. O robô possui a meta inicial `!limparAmbiente(roboto)`. Para atingir esta meta, executa o Plano 1 (linhas 8 a 11), que ativa a intenção de `!verificarLocal(roboto)` e executa as ações `limpar(roboto)` e `andar(roboto, 1)`. A intenção `!verificarLocal(roboto)` ativa o Plano 2 (linhas 14 a 16), que remove as crenças de localização anteriores e atualiza as crenças de acordo com o modelo proposto.

Quando o robô possui a crença `local(Comodo, Grau)` com grau de certeza de pelo menos 0,6, o Plano 3 (linhas 19 e 20) é executado. O Plano 3 executa a ação `selecionarMateriais(Comodo)`. Quando o robô não possui nenhuma crença com grau de confiança maior que 0,6, é executado o Plano 4 (linhas 23 a 25), que realiza a ação `esperar(5)` e ativa a intenção de verificar sua localização novamente.

No início da execução, o Robô tem as seguintes percepções geradas pelo modelo: `local(C1, 0.3) ; local(C2, 0.2) local(Q1, 0.2);`

`local (Q2, 0.3)`. Como não possui grau de confiança alto em nenhuma das suas crenças, a ação do robô é aguardar 5 segundos e atualizar suas crenças. Após atualizar suas crenças, as novas percepções do robô são: `local (C1, 0.1)`; `local (C2, 0.2)` `local (Q1, 0.6)`; `local (Q2, 0.1)`. Acreditando estar em Q_1 com 0.6 de certeza, o robô seleciona os materiais para a limpeza de Q_1 , realiza a limpeza e locomove-se para outra posição (Código 1).

```
[robo] doing:  esperar(robo, 5)
[robo] doing:  atualizarCrenças(robo)
[robo] doing:  selecionarMateriais(robo, q1)
[robo] doing:  limpar(robo)
[robo] doing:  andar(robo, 1)
```

Código 1. Execução do Robô Limpador como Agente BDI

5. Considerações Finais

Com o intuito de obter a consciência situacional de um agente em nível de Percepção, este trabalho apresentou um modelo de fusão de dados. Para tratar a incerteza inerente de dados sensoriais, o modelo emprega inferência *Fuzzy*-Bayesiana. A saída do modelo é um conjunto de crenças com grau de certeza e são propagadas para os níveis de consciência situacional de Compreensão e Projeção, de modo a possibilitar o posterior raciocínio, planejamento e a tomada de decisão do agente. O uso da inferência Bayesiana permite estimar a probabilidade mesmo no caso de não serem observadas todas as evidências do ambiente, assim, se um sensor falhar, as crenças do agente ainda serão formadas.

Contudo, a abordagem *Fuzzy*-Bayesiana não permite a geração de crenças de saída difusas, pois não é possível usar a rede como um regressor. Esta característica, afeta agentes que precisem fazer uso da crença difusa em um controlador. Além disso, a crença difusa poderia ser empregada como entrada para outras redes *Fuzzy*-Bayesianas ou em sistemas *fuzzy*. Faz-se necessário ainda, considerar que o ambiente observado pelo agente possui características variantes no tempo. Esta variação pode ser introduzida no modelo através da incorporação de medições passadas à observação presente. Neste sentido, como trabalhos futuros, pretende-se explorar o uso de inferência de Redes Bayesianas Dinâmicas no modelo proposto. Para exemplificar a necessidade de explorar a continuidade nos dados, usaremos novamente o exemplo do Robô Limpador. Suponha que o robô estime sua localização a cada k segundos e consiga apenas locomover-se um passo durante este intervalo. Considerando que as características de ambos os corredores C_1 e C_2 são similares, poderia ocorrer de o robô deduzir que sua localização em um instante t seja C_1 e no instante $t + 1$, seja C_2 . Devido à disposição dos cômodos no cenário (Figura 2), sabe-se que não é possível movimentar-se de C_1 para C_2 em apenas um passo, assim, a dedução do robô seria inverossímil. Utilizando observações probabilísticas contínuas, o robô teria informações para julgar que, ao estar em C_1 no instante t , a probabilidade de continuar em C_1 ou mesmo de entrar em um dos quartos Q_1 ou Q_2 no instante $t + 1$ é maior do que a probabilidade de ter atingido o corredor C_2 .

Como trabalhos futuros, pretende-se implementar o modelo em um cenário robótico real, no qual seja possível explorar a tomada de decisão do agente e a escalabilidade da abordagem.

Referências

- Brignoli, J. T., Pires, M. M., Nassar, S. M., and Sell, D. (2015). A fuzzy-Bayesian model based on the superposition of states applied to the clinical reasoning support. *IntelliSys 2015 - Proceedings of 2015 SAI Intelligent Systems Conference*, pages 210–219.
- Chen, L., Nugent, C., and Al-Bashrawi, A. (2009). Semantic Data Management for Situation-aware Assistance in Ambient Assisted Living. In *Proceedings of the 11th International Conference on Information Integration and Web-based Applications & Services, iiWAS '09*, pages 298–305, New York, NY, USA. ACM.
- Endsley, M. R. (1995). Toward a Theory of Situation Awareness in Dynamic Systems. *Human Factors: The Journal of the Human Factors and Ergonomics Society*, 37(1):32–64.
- Golestan, K., Soua, R., Karray, F., and Kamel, M. S. (2016). Situation awareness within the context of connected cars: A comprehensive review and recent trends. *Information Fusion*, 29:68–83.
- Insaurralde, C. C. and Petillot, Y. R. (2015). Capability-oriented robot architecture for maritime autonomy. *Robotics and Autonomous Systems*, 67:87–104.
- Khaleghi, B., Khamis, A., Karray, F. O., and Razavi, S. N. (2013). Multisensor data fusion: A review of the state-of-the-art. *Information Fusion*, 14(1):28–44.
- Kokar, M. M., Matheus, C. J., and Baclawski, K. (2009). Ontology-based situation awareness. *Information Fusion*, 10(1):83–98.
- Koller, D. and Friedman, N. (2009). *Probabilistic graphical models: principles and techniques*. MIT press.
- Steinberg, A. N. and Bowman, C. L. (2004). Rethinking the JDL Data Fusion Levels. *NSSDF Conference Proceedings*, (c):1–18.
- Viertl, R. (1987). Is it Necessary to Develop a Fuzzy Bayesian Inference ? In Viertl, R., editor, *Probability and Bayesian Statistics*, pages 471–475. Springer US, Boston, MA.
- Viertl, R. (1989). Modeling of Fuzzy Measurements in Reliability Estimation.
- Viertl, R. (1995). Statistics with Fuzzy Data. In Della Riccia, G., Kruse, R., and Viertl, R., editors, *Proceedings of the ISSEK94 Workshop on Mathematical and Statistical Methods in Artificial Intelligence*, pages 33–49, Vienna. Springer Vienna.
- Viertl, R. (2008). Fuzzy Bayesian Inference. *Smps*, pages 10–15.
- Viertl, R. and Hule, H. (1991). On Bayes ' theorem for fuzzy data. *Statistical Papers*, 32:115–122.
- White, F. E. (1988). A model for data fusion. In *Proc. 1st National Symposium on Sensor Fusion*, volume 2, pages 149–158.
- Wickens, C. D. and Hollands, J. G. (2000). *Engineering Psychology and Human Performance*. Prentice Hall, Upper Saddle River, New Jersey, 3 edition.
- Zadeh, L. (1965). Fuzzy sets. *Information and Control*, 8(3):338–353.