

NOVELTY DETECTION FOR SEMANTIC PLACE CATEGORIZATION

André Susano Pinto[†]

Sob orientação de: Andrzej Pronobis[‡], Luis Paulo Reis[†]

[†]Faculdade de Engenharia da Universidade do Porto, Portugal

[‡]Royal Institute of Technology (KTH), Stockholm, Sweden

1. Motivação

Já à muitos anos que a humanidade sonha que um dia robôs caminharam lado a lado com os humanos. Acredita-se que eles serão capazes de se mover e interagir conosco, compreender os nossos conceitos e serem capazes de pensar. Um passo importante nesta direcção é a criação de robôs com conhecimento de conceitos e significados próprios do mundo humano. No entanto é irrealista acreditar que será possível descrever e representar em toda a sua extensão tais conceitos. Assim os agentes deverão ser capazes de aprender e adaptar o seu conhecimento quando confrontados com novas situações. A detecção destas novas situações, onde o conhecimento de um agente não é suficiente, têm um papel importante na adaptação e aprendizagem de novos conceitos e significados e é por isso o tópico principal desta tese.

No contexto de agentes móveis, para facilitar o deslocamento e planeamento, os agentes constroem uma representação do ambiente. Quando essa representação é estendida com conceitos e categorias com significado para humanos, as tarefas de alto nível ficam mais fáceis. Por exemplo, a uma escala de quartos, os humanos categorizam o espaço em: cozinhas, quartos, corredores, escritórios, etc... Ao relacionar quartos com estas categorias que descrevem propriedades e acções percebidas por humanos, um agente consegue resolver tarefas como: “Onde estão os cereais?”

2. Problema e Objectivos

O processo de mapeamento semântico têm um papel importante na capacidade pensativa de um agente. Em simultâneo, esse processo está limitado pelo conhecimento em conceitos e significados do mundo humano. É então importante estudar e analisar técnicas que sejam capazes de detectar falhas no conhecimento e permitir ao agente agir de maneira cuidadosa. É com esse objectivo que a tese aqui descrita se foca no estudo de técnicas de detecção de situações novas e de como as aplicar num processo de mapeamento semântico com vista a detectar novas categorias de lugares em ambientes interiores. Para esse fim, a tese estuda o processo de mapeamento semântico proposto por [1], e procura solucionar a detecção de novas categorias usando modelos gráficos.

3. Mapeamento Semântico

Mapeamento semântico é o processo através do qual um agente constrói uma representação do ambiente estendida com conceitos e categorias com significado especial (i.e. conceitos humanos). Neste tese o processo proposto por [1] foi usado como base.

3.1. Conhecimento Espacial

O conhecimento espacial de agente define a informação necessária para o mapeamento semântico, e inclui informação em como segmentar e identificar entidades e propriedades através dos dados recolhidos. Para esse fim [2] utiliza uma representação estruturada em camadas: a *camada de sensores* mantém uma descrição exacta do ambiente numa representação de baixo nível; a *camada de lugares* segmenta e identifica áreas e conceitos como quartos; a *camada de categorias* é responsável por definir conhecimento sobre propriedades e categorias e permite ao agente obter informação de mais alto nível; e a *camada de conceitos* mantém conhecimento sobre os diversos conceitos, relações entre os mesmos e informação de como os mapear para conceitos humanos.

3.2. Mapa Conceptual

Durante o processo de mapeamento semântico o agente utiliza a ontologia da camada conceptual para produzir um mapa conceptual. Este é produzido usando modelos gráficos probabilísticos que relacionam os conceitos detectados e propagam probabilidades entre os mesmos de acordo com o conhecimento do agente. A detecção de uma nova categoria no conhecimento do agente traduz-se na detecção de um novo estado nas variáveis de tal grafo e portanto os mapas conceptuais são usados como ferramenta para detecção de novas categorias.

4. Novelty Detection

Novelty detection, também conhecido por *detecção de anomalias* ou *detecção de outliers*, é o problema de detecção que os dados foram produzidos por uma nova classe, sobre a qual o agente não têm conhecimento [3]. A habilidade de detectar estes casos é de fulcral importância em sistemas autónomos que operam em ambientes desconhecidos. Pois permite detectar que algo está fora do normal e assim actuar com cuidado.

4.1. Novelty Detection através de Thresholds

Devido a ruídos e incerteza existentes nos dados, a detecção de casos novos é tratada com probabilidades. Assim para cada amostra de dados x existe uma certa probabilidade de a mesma ser gerada por uma classe desconhecida e uma probabilidade complementar $P(\overline{novel}|x)$ de ser por uma classe conhecida.

Além disso, qualquer detector por ser descrito unicamente pelo conjunto N de amostras que classifica como novas. Com isso é possível demonstrar que ao expandir o conjunto N com um novo elemento a , o agente aumenta a taxa de detecção a um custo de produzir mais classificações erradas. Isto descreve o princípio de troca entre erro e rejeição descrito por [4]. Um detector óptimo, é assim equivalente ao problema da mochila com quantidades fracionárias, pois têm como objectivo obter a maior taxa de detecção com uma taxa de erro máximas. Assim qualquer detector óptimo pode ser descrito através de um limite imposto sobre a relação gulosa dado por:

$$P(\overline{novel}|x) = \frac{P(x|\overline{novel})P(\overline{novel})}{P(x)} \quad (1)$$

4.2. Critério: $P(\overline{novel})$ como Constante

Ao considerar $P(\overline{novel})$ constante, uma relação equivalente pode ser obtida usando somente a fracção entre $P(x|\overline{novel})$ e $P(x)$. Apesar de parecer inofensivo, o caso apresentado neste tese é diferente dos casos normais em que todos as amostras são geradas através de uma categoria. Aqui toda estrutura e relação entre as variáveis toma um papel na geração de amostras e portanto não é claro como tal critério se comporta na realidade.

4.3. Modelar $P(x|\overline{novel})$

O modelo gráfico produzido durante o mapeamento semântico, modela a distribuição de todas as variáveis assumindo que o conhecimento do agente é representativo da realidade, como tal pode ser usado para aproximar $P(x|\overline{novel})$.

4.4. Modelar $P(x)$

Sem conhecimento sobre a distribuição real é correcto modela-la usando uma distribuição uniforme. No entanto, o agente considera que todo o seu conhecimento é representativo da realidade à excepção da categoria de uma das suas variáveis. Nesse caso a aproximação correcta é substituir os factores dependentes dessa variável por um único factor. Devido à dimensão do mesmo, é inviável aproximá-lo sem realizar simplificações. A tese apresenta assim duas aproximações: um modelo uniforme e um modelo independente. No modelo independente esse factor é aproximado com vários factores dependentes somente numa variável. Esses podem facilmente ser aproximados e é esperado que obtenham melhores resultados ao compensar por uma tendência do ambiente em gerar certas *features*.

5. Resultados

Para testes um conjunto de dados sintético foi preparado. Este aproxima as propriedades esperadas num cenário realístico como por exemplo um número variável de *features*. Os modelos sugeridos foram comparados entre eles e entre um detector óptimo, e os testes realizados mostram o comportamento dos modelos em diversas situações, por exemplo conforme mais informação é recolhida pelo agente.




Fig. 1 – Comparação dos modelos propostos usando dados sintéticos com número variável de *features*.

6. Conclusão

Esta tese estudou o problema da detecção de novas categorias de espaços interiores no contexto de agentes móveis. Para tal o processo de mapeamento semântico [2] foi estudado e um mecanismo de detecção, baseado no mapa conceptual usado pelo mesmo, foi proposto. Foram realizados testes iniciais com dados sintéticos, mostrando o benefício de usar dados não supervisionados. Adicionalmente toda a teoria e assunções por trás do método apresentado foram documentadas, incluindo discussão de diversas direcções futuras em como criar uma *framework* generalizada para detecção de casos novos no conhecimento semântico e espacial de agentes.

Referências

- [1] Andrzej Pronobis. *Semantic Mapping with Mobile Robots*. PhD thesis, Royal Institute of Technology (KTH), Stockholm, Sweden, June 2011.
- [2] Andrzej Pronobis and Patric Jensfelt. Understanding the real world: Combining objects, appearance, geometry and topology for semantic mapping. Technical Report TRITA-CSC-CV 2011:1 CVAP319, Kungliga Tekniska Högskolan, CVAP/CAS, May 2011.
- [3] M. Markou and S. Singh. Novelty detection: a review—part 1: statistical approaches. *Signal Processing*, 83(12):2481–2497, 2003.
- [4] C. Chow. On optimum recognition error and reject tradeoff. *Information Theory, IEEE Transactions on*, 16(1):41–46, 1970.