

Explicabilidade em Métodos de Aprendizado de Máquina usando Ontologia e Inferência Lógica

Juan Manuel Iglesias Pascual¹, Leonardo Anjoletto Ferreira²

¹ Ciências da Computação, Fundação Educacional Inaciana "Pe. Sabóia de Medeiros" (FEI)

² Engenharia Elétrica, Fundação Educacional Inaciana "Pe. Sabóia de Medeiros" (FEI)

unifjpascual@fei.edu.br e laferreira@fei.edu.br

Resumo: Métodos de Aprendizado Profundo vem mostrando bons resultados em problemas de reconhecimento de objetos em imagens, porém, explicar como estes objetos foram reconhecido é uma tarefa custosa quando se consegue realizá-la. Este trabalho visa utilizar uma base de ontologias com mecanismos de inferência e raciocínio para viabilizar a explicação de alguns conteúdos encontrados dentro de imagens, e.g. a relação espacial entre objetos reconhecidos.

1. Introdução

O reconhecimento de objetos em imagens utilizando métodos de Aprendizado Profundo tem um desempenho excelente e robusto. As Redes Neurais Profundas (DNN) são capazes de fornecer informações sobre a localização do objeto ou até mesmo uma descrição da imagem na forma de uma legenda. Entretanto o raciocínio sobre as informações e conceitos destes objetos só é possível a partir do treinamento da rede com exemplos contendo estas informações.

Por exemplo, para uma DNN gerar a descrição “O livro está sobre a mesa” é necessário treinar uma rede com exemplos de “livro”, “mesa” e “sobre” de forma que a rede consiga reconhecer os dois objetos (“livro” e “mesa”) e, considerando a posição destes na imagem, consiga reconhecer a relação “sobre”. Entretanto, ao inverter a relação caracterizada na imagem gerando a descrição “A mesa está sob o livro”, a rede deve ser treinada para reconhecer a relação “sob”. Não seria difícil obter exemplos, neste caso, da relação “sob”, porém o tempo necessário para gerar os exemplos e fazer o treinamento superam os custos e recursos necessários para realizar a mesma tarefa utilizando raciocínio, em que seria necessário apenas explicitar que são relações inversas, ou seja, considerando dois objetos A e B, A estar sobre B implica que B está sob A (i.e., sobre(A, B) => sob(B, A). Para tanto, este trabalho, propõe uma notação mais próxima a utilizada na implementação de sistemas que utilizam de conhecimento e raciocínio (KRR) para complementar as informações sobre objetos reconhecidos por uma DNN em imagens e assim evidenciar as inferências.

2. Revisão bibliográfica

Métodos de aprendizado de máquina como as redes neurais e especialmente as DNN são consideradas por muitos como *black box* pois explicar o que ocorre

durante o processo de obtenção de uma saída para uma certa combinação de entradas é atualmente inviável em alto nível usando apenas as diversas operações realizadas dentro da rede.

Uma abordagem para tratar estes problemas de explicação das respostas de redes neurais é o uso de conhecimento em alto nível como os que podem ser descritos em ontologias, ou um padrão de dados para representar a informação contida na imagem, para que um computador possa realizar inferências lógicas.

A base de ontologias denominada Suggested Upper Merged Ontology (SUMO) surgiu da união de conteúdos ontológicos publicamente disponíveis, inclusive WordNet, sendo base para o Standard Upper Ontology (SUO), um grupo sob a IEEE, que tinha como objetivos resolver problemas ligados a necessidade de geração de grandes bases de ontologia de forma aberta e gratuita utilizando um padrão público (Pease, 2011).

A partir de uma base de ontologias desenvolvida na sintaxe do SUMO, é possível realizar inferências usando o Sigma Knowledge Engineering Environment (SigmaKEE). Já o Sigma Natural Language Processing (SigmaNLP) permite análise sintática de frases e sua transcrição em regras na sintaxe do SUMO e que podem ser adicionadas à base de ontologias.

3. Metodologia

Este projeto foi dividido em 3 partes:

1. **Implementação da Rede Neural:** dentre todos os modelos fornecidos para a biblioteca TensorFlow (2019) foi escolhido o *faster_rcnn_nas* treinado utilizando a base de imagens MS-COCO (LIN *et. al.*, 2014) que fornece, além da classe do objeto, o *bounding box* dos objetos reconhecidos em uma imagem e a probabilidade de o objeto fazer parte da classe escolhida. Estas informações serão utilizadas na terceira parte do projeto para realizar a descrição das relações dos objetos encontrados, a classificação da imagem e também a explicação do motivo de ter sido escolhida a respectiva classificação.
2. **Desenvolvimento da base de conhecimento:** a base de ontologia SUMO fornece uma grande quantidade de informações e também de funções que podem ser utilizadas para a realização de inferências. O objetivo desta parte do projeto é descrever a relação dos prédios do campus de São Bernardo do Campo do Centro Universitário FEI, permitindo que inferências sobre as relações dos

prédios possam ser realizadas e que o conhecimento sobre o funcionamento do SUMO e do SigmaKEE possa ser aprofundado.

3. Desenvolvimento do sistema de classificação de imagens e explicação da classificação: etapa que ainda não foi iniciada e que visa implementar um classificador de cenas internas e externas que permita a explicação do resultado da classificação. Esta etapa utilizará o SigmaREST (implementação da API REST para o SigmaKEE) e fará a troca de informações entre a DNN escolhida e a base de ontologia. A forma como serão classificadas as imagens em relação aos objetos encontrados ou as relações entre eles ainda não foram definidas.

4. Resultados Parciais

Foram descritos dois tipos de função na base de ontologias. O primeiro tipo diz respeito à inversão das relações espaciais e a segunda sobre a extensão destas relações para outros objetos. Por exemplo, dados objetos A, B e C, o primeiro tipo de relação diz que se sabemos que A está acima de B, então podemos inferir que B está abaixo de A (i.e., $acima(A, B) \Rightarrow abaixo(B, A)$). Já o segundo tipo de relação permite inferir que se A está acima de B e B está acima de C, então A está acima de C (i.e., $acima(A, B), acima(B, C) \Rightarrow acima(A, C)$). Estas relações na sintaxe utilizada pelo SUMO encontram-se na figura 1.

Com o sistema de reconhecimento de objetos e as descrições das relações espaciais já desenvolvidas e a comunicação entre a saída do classificador e o SUMO já implementadas, os próximos passos visam desenvolver as funções que fazem a inferência utilizando o SigmaKEE e, em seguida, a classificação da imagem.

5. Conclusões

Este projeto tem como objetivo unir o reconhecimento de objetos em imagens que é realizado por uma Rede Neural Profunda com o raciocínio que pode ser feito a partir de informações extraídas desta mesma imagem resultando em um classificador de cenas que indica se a imagem fornecida é de um ambiente interno ou externo que consiga, além de classificar, explicar porque a escolha de determinada classe foi feita.

Até o momento, a implementação da Rede Neural foi realizada de forma rápida por contar com um ambiente de fácil utilização e boa documentação. Entretanto, a dificuldade em implantar o ambiente SigmaKEE e compreender a sintaxe utilizada pelo SUMO apresentou grandes desafios que estão sendo tratados e serão resolvidos para a continuação do projeto.

As próximas etapas do projeto concentram-se, portanto, no término do aprendizado da utilização do SigmaKEE e do desenvolvimento do classificador desejado, além da análise do desempenho deste classificador.

```

SUMORelacoesEspaciais.tst
1 .....
2 |          S U M O
3 |          notas para relações de localização no campus FEI SBC
4 .....
5
6 (norte G H)
7 (norte G? H?)
8 (=) sul H? G?)
9
10 (leste H T)
11 "leste H? T?"
12 (=) oeste T? H?"
13
14 (=)
15 ((norte A? B?)
16 (norte B? C?)
17 (norte A? C?))
18
19 (=)
20 ((leste A? B?)
21 (leste B? C?)
22 (leste A? C?))
23
24
25 (=)
26 (leste A? B?)
27 (oeste B? A?))
28
29 (=)
30 (norte A? B?)
31 (sul B? A?))
32
33

```

Fonte: Autor

Figura 1: Relações espaciais na sintaxe do SUMO

6. Referências

Pease, Adam. **Ontology: A Practical Guide**. Articulate Software Press. Angwin, CA. 2011.

TensorFlow. **Tensorflow detection model zoo**. 2019. Disponível em: https://github.com/tensorflow/models/blob/master/research/object_detection/. Acessado em 24 de julho de 2019.

Lin, Tsung-Yi, Michael Maire, Serge Belongie, James Hays, Pietro Perona, Deva Ramanan, Piotr Dollár, e C. Lawrence Zitnick. **Microsoft COCO: Common Objects in Context**. In *European conference on computer vision*, pp. 740-755. Springer, Cham, 2014.

Antol, Stanislaw, Aishwarya Agrawal, Jiasen Lu, Margaret Mitchell, Dhruv Batra, C. Lawrence Zitnick, e Devi Parikh. **VQA: Visual Question Answering**. In *Proceedings of the IEEE international conference on computer vision*, pp. 2425-2433. 2015.

Agradecimentos

Ao Prof. Dr. Paulo Eduardo Santos pela ajuda ao longo do desenvolvimento dos conceitos usados neste projeto e ao Dr. Adam Pease pelo suporte durante a implantação e o aprendizado do ambiente SigmaKEE.

¹ Aluno de IC do Centro Universitário FEI. Projeto com vigência de 02/19 a 01/20.