

UNIVERSIDADE FEDERAL DE PERNAMBUCO
Centro de Informática
Graduação de Sistemas de Informação

**ANÁLISE COMPARATIVA DE MODELOS DE DEEP LEARNING
BASEADOS EM INTERPRETABILIDADE NO CONTEXTO DE
PATOLOGIA COMPUTACIONAL**

Proposta de Trabalho de Graduação

Aluno: Márcio de Aquino Soares Filho (masf@cin.ufpe.br)

Orientador: Fernando Maciano (fernando@cin.ufpe.br)

Área: Ciência de dados / Aprendizado de Máquina

Recife, 2021

SUMÁRIO

1. Resumo.....	3
2. Contexto.....	4
3. Objetivo.....	6
4. Metodologia.....	7
5. Cronograma.....	8
6. Possíveis avaliadores.....	9
7. Referências bibliográficas.....	10

Resumo

O uso de Deep Learning no contexto de saúde, especificamente na patologia computacional, enfrenta alguns desafios, entre eles a falta de interpretabilidade em modelos. Entretanto, o avanço no desenvolvimento das redes neurais tem permitido que seja possível ampliar a capacidade de interpretabilidade dos modelos, tornando assim seus resultados capazes de gerar mais valor além da classificação/predição.

Considerando esse cenário, a proposta desse trabalho é realizar o treinamento de alguns modelos baseados em interpretabilidade, utilizando a base CAMELYON16, e comparar os resultados de cada um desses modelos. Os modelos serão treinados com ProtoPNet, Grad-CAM, Part R-CNN e MG-CNN

Palavras chaves: Deep Learning, Interpretabilidade, Patologia computacional, Redes Neurais

Contexto

A aplicação de redes neurais no ambiente de Saúde, mais especificamente no âmbito da patologia computacional, acabou se dando de forma um tanto quanto atrasada em relação a outras áreas(CAMPANELLA), isso ocorreu devido a alguns fatores limitantes naturais da área de aplicação.

A área da patologia clínica sempre se manteve bastante conservadora, em decorrência disso, seus métodos também se mantiveram tradicionais por um bom tempo, assim como a geração de dados. Como consequência, uma parte dos dados é baseada na digitalização de materiais antigos, que acabam se tornando dados consideravelmente pesados, ou dados recentes em boa qualidade, mas que também são custosos em termos de espaço e processamento.

Além do problema da geração de dados há uma parcela das barreiras de entrada para a exploração de Deep Learning na saúde que vem da falta da interpretabilidade da maioria dos modelos mais tradicionais, tendo em vista que no contexto em que se encontra é de extrema importância que os resultados possuam significado e sejam visíveis para o profissional de saúde(VELLIDO).

Com o aumento do desenvolvimento e pesquisa na área de redes neurais e interpretabilidade, já existem alguns trabalhos que tentaram lidar com os problemas da aplicação da patologia computacional, onde um dos maiores problemas se dá devido a natureza dos dados para o treinamento que os torna extremamente custosos em relação ao tempo de treino. Como forma de evitar esse problema, em um dos trabalhos, o modelo foi treinado apenas com dados de diagnósticos reportados, e os resultados foram bastante positivos, mantendo-se acima de 0.98 o resultado nos testes. Permitindo assim eliminar 65-75% dos slides utilizados no treino e manter 100% de sensibilidade(CAMPANELLA).

Enquanto alguns trabalhos têm sido diretamente aplicados no ambiente da patologia computacional, outros com um maior enfoque em interpretabilidade, porém não no contexto de patologia computacional, foram realizados permitindo uma maior variedade de abordagens para manter o treinamento de modelos que sejam mais interpretáveis, utilizando arquiteturas como ProtoPNet, faz uso de protótipos para aumentar a interpretabilidade e ainda reforçar os resultados, conseguindo assim resultados semelhantes a outras arquiteturas não-interpretáveis(CHEN).

Tendo em vista o contexto explicitado, esse trabalho entra como um ponto em comum entre esses problemas, com o objetivo de aplicar esses métodos que vem sendo aprimorados em uma base de patologia computacional e produzir resultados comparativos sobre suas utilizações. Possibilitando uma ciência sobre quais métodos se encaixam melhor na questão.

Objetivo

epositórios React NatiO objetivo geral desse projeto é explorar modelos de deep learning baseados em interpretabilidade, aplicados em um contexto de patologia computacional.

Dado o contexto e a base de dados utilizada, CAMELYON16, para atingir esse objetivo geral, teremos como um dos objetivos específicos, a realização do treinamento de modelos baseados em interpretabilidade, treinando os modelos com ProtoPnet, Grad-CAM, Part R-CNN e MG-CNN, na base de dados citada.

Em seguida, será feita uma análise comparativa estatística utilizando as medidas de desempenho de classificadores e interpretadores de CNN.

Metodologia

A metodologia que será utilizada para a realização desse trabalho consistirá no uso de artigos disponíveis que sejam úteis em uma revisão bibliográfica da área, além da utilização ferramentas da linguagem Python, como a biblioteca Sklearn aplicadas na base de dados pública disponível CAMELYON16.

Cronograma

Atividades	Junho	Julho	Agosto
Revisão da literatura			
Treinamento dos modelos			
Análise dos resultados/ Escrita da monografia			
Defesa			

Possíveis avaliadores

Um possível avaliador para esse trabalho é o professor Leandro Almeida (CIn/UFPE)

Referências bibliográficas

CAMPANELLA, Gabriele; HANNA, Matthew G.; GENESLAW, Luke; *et al.* **Clinical-grade computational pathology using weakly supervised deep learning on whole slide images.** *Nature Medicine*, v. 25, n. 8, p. 1301–1309, 2019.

CHEN, Chaofan; LI, Oscar; TAO, Chaofan; *et al.* **This Looks Like That: Deep Learning for Interpretable Image Recognition.** 2018. Disponível em: <<https://arxiv.org/abs/1806.10574v5>>. Acesso em: 20 fev. 2021.

SELVARAJU, Ramprasaath R.; COGSWELL, Michael; DAS, Abhishek; *et al.* **Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization.** *International Journal of Computer Vision*, v. 128, n. 2, p. 336–359, 2020.

VELLIDO, Alfredo. **The importance of interpretability and visualization in machine learning for applications in medicine and health care.** *Neural Computing and Applications*, v. 32, n. 24, p. 18069–18083, 2020.