

Universidade de Pernambuco

Programa de Pós-Graduação em Engenharia da Computação (PPGEC)

Proposta de Tese de Doutorado

Área: Inteligência Computacional

Título: Detecção de cenários de diagnósticos negativos usando Deep Learning

Orientador – Carmelo José Albanez Bastos Filho (carmelofilho@upe.br)

Descrição

Exames de imagens médicas são cruciais para o suporte ao diagnóstico em várias áreas da saúde. Segundo dados da OMS(Organização Mundial de Saúde)[1], o crescimento das políticas de acesso ao diagnóstico e o número disponível de equipamentos médicos são responsáveis pelo crescimento do número de exames no mundo.

A interpretação dos exames de imagens dependem de médicos especialistas em cada área. Dados assistenciais da ANS(Agência Nacional de Saúde)[2] estimam que são realizados aproximadamente 40 milhões de exames de imagem por ano no Brasil. O volume de exames afeta diretamente no tempo do diagnóstico, visto que existem aproximadamente 452 mil médicos registrados[3] no país, não necessariamente com especialidades para efetuar algum diagnóstico preciso sobre o resultado do exame de imagem.

Uma das formas de aumentar a eficiência no tempo dos diagnósticos em exames de imagens está relacionado a como automatizar o processo de detecção de padrões de patologias nos exames de imagens. Técnicas de Deep Learning tem sido utilizadas como ferramentas no apoio ao diagnóstico em exames de imagens como Ressonâncias Magnéticas, Tomografia e Radiologia[4].

Deep Learning[6] ou Aprendizado Profundo são técnicas de Aprendizagem de Máquina compostas por várias camadas de processamento capazes de aprender e extrair conhecimento a partir de dados em vários níveis de abstração. Estas técnicas são utilizadas em larga escala na área de detecção de padrões e objetos em imagens. Podemos observar a aplicação de Deep Learning na segmentação de exames de próstata ou mesmo na área de histopatologia, no reconhecimento de células[5].

Ainda assim, uma das grandes restrições nas aplicações de Reconhecimento de Padrões para área de exames de imagens está em um grande número dos casos tidos como normais ou negativos, onde não são apresentados os padrões que apontam alguma patologia ou indicativo de algo que afete a saúde de um paciente. Estes casos concorrem em tempo de análise executado pelos médicos especialistas nas filas de diagnósticos.

Uma das abordagens para contorno deste cenário está na possibilidade de utilizar técnicas de Deep Learning para a detecção de anomalias. Para este caso, as anomalias seriam consideradas o agrupamento das características de exames negativos, dados que não há padrões bem definidos para determinar os casos negativos. Com a descoberta dessas classes, seria possível criar um ordenamento destas filas baseados nas probabilidades de certas classes se repetirem mais para casos negativos.

O objetivo deste projeto visa avaliar modelos e técnicas e modelos de Deep Learning que sejam capazes de generalizar, através da detecção de anomalias, os casos negativos em exames de imagens. Como metodologia para o projeto proposto, será necessário construir um banco de imagens de casos negativos para um grupo de doenças que podem ser diagnosticadas através de exames de imagens e a validação dos modelos frente a um grupo de médicos especialistas.

Referências Bibliográficas

1. Disponível em: http://www.who.int/diagnostic_imaging/en/, acessado em 08/11/2018.
2. Disponível em: <http://www.ans.gov.br/perfil-do-setor/dados-e-indicadores-do-setor>, acessado em 08/11/2018.
3. SCHEFFER, M. et al. Demografia Médica no Brasil 2018. São Paulo, SP: FMUSP, CFM, Cremesp, 2018. 286 p. ISBN: 978-85-87077-55-4
4. GREENSPAN, Hayit; VAN GINNEKEN, Bram; SUMMERS, Ronald M. Guest editorial deep learning in medical imaging: Overview and future promise of an exciting new technique. IEEE Transactions on Medical Imaging, v. 35, n. 5, p. 1153-1159, 2016.
5. SHEN, Dinggang; WU, Guorong; SUK, Heung-II. Deep learning in medical image analysis. Annual review of biomedical engineering, v. 19, p. 221-248, 2017.
6. LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. Deep learning. nature, v. 521, n. 7553, p. 436, 2015.