

COMPARAÇÃO ENTRE DUAS REDES NEURAIS CONVOLUCIONAL NA ANÁLISE DE DISPLASIA COXOFEMORAL EM CÃES

Paulo de Tarso Maia Monteiro¹; Mayara Cristtine Ramos²; Izadora da Rocha Costa²; Laura Dias Petricione de Souza²; Fabio Raphael Pascoti Bruhn²; Guilherme Albuquerque de Oliveira Cavalcanti³

¹Universidade Federal de Pelotas – paulodetarso753159@gmail.com

²Universidade Federal de Pelotas – mayaracramos@outlook.com.br

²Universidade Federal de Pelotas – izadoracosta18@hotmail.com

²Universidade Federal de Pelotas – laurapetricione@gmail.com

²Universidade Federal de Pelotas – fabio_rpb@yahoo.com.br

³Universidade Federal de Pelotas – guialbuquerque@yahoo.com

1. INTRODUÇÃO

A displasia coxofemoral (DCF) é uma doença debilitante em cães de médio e grande porte, quanto mais precoce o diagnóstico, melhor a qualidade de vida que se pode oferecer ao animal. Por ser uma enfermidade com certo caráter hereditário, o controle da mesma na população canina se dá através do acasalamento, evitando procriação de animais displásicos, sendo essa uma preocupação em criadores de raças específicas. Com isso buscamos aprimorar meios de estudo sobre a mesma, sendo então utilizado o uso de inteligência artificial.

A inteligência artificial vem se introduzindo cada vez mais nos campos da medicina, principalmente na medicina humana. Dito isto, se faz necessário a realização de estudos sobre as diversas características e opções disponíveis sobre o ramo de inteligência artificial. Neste estudo abordamos uma categoria de inteligência artificial, que também chamamos de redes neurais, dentre os diversos modelos e tipos de arquiteturas na categoria de redes neurais, trabalhamos com a arquitetura CNN (rede neural convolucional). Essa arquitetura de rede é bastante utilizada em classificação de imagens, podendo ter outras aplicações também. A utilização da CNN neste estudo foi realizada pois a mesma é uma rede profunda que contém uma alta capacidade de abstração de informação dos dados (HANS 2018).

Foi realizada a comparação de duas redes para identificação e classificação de displasia coxofemoral em cães, através da análise de um banco de dados contendo imagens radiográficas de DCF em cães. Uma das redes é a famosa VGG19, ela é uma rede aberta pré-treinada com milhões de parâmetros, a outra rede foi criada e utilizada em um estudo publicado pelo grupo recentemente. Com isso podemos comparar a qualidade de redes grandes com um aprendizado pré pronto, em relação a redes com menos parâmetros, visando um estudo sobre uma rede com melhor adaptação para imagens radiográficas.

2. METODOLOGIA

As redes foram construídas utilizando a plataforma google colab, que é uma plataforma para programação em python, onde a mesma tem integração com servidor disponibilizado pela google para poder fazer o processamento das redes, visto que redes neurais e principalmente CNN por serem profundas, necessitam de uma alta capacidade de processamento.

O banco de dados utilizado foi composto por 190 imagens radiográficas, sendo elas 130 imagens de animais diagnosticados com displasia coxofemoral e 60 animais sadios. As imagens são radiografias da pelve de cães, sendo elas necessárias para o clínico veterinário diagnosticar se um animal é displásico ou não.

Para o seguinte trabalho foi então feito uma CNN do zero, sem aprendizado prévio e a outra rede, uma CNN VGG19 já com 20 milhões de parâmetros aprendidos pela mesma. Realizado o pré-processamento das imagens do banco de dados, onde as mesmas foram redimensionadas em tamanho de 224x224 pixels, junto com a normalização das imagens, onde dividimos os pixels por 255, para termos valores entre 0 e 1. Utilizando técnicas de aumento do banco de dados, como rotação, zoom de 20% e flip nas imagens, elas não prejudicam o banco de dados atual, porém é válido pensar que nem em todos os bancos de dados é ideal fazer essas alterações. O banco de dados foi dividido em duas partições, sendo uma delas para treinamento, contendo 80% das imagens e a outra parte para teste, onde contém 20% das imagens, foram separadas aleatoriamente pela função train test split.

Utilizando a função Dropout para desligar uma parte dos neurônios na camada densa, aplicada durante o período de treinamento das redes, visto que isso ajuda a reduzir o overfitting (LI 2014). Utilizando um dropout no valor de 0.4 onde representa que 40% dos neurônios dessa camada estarão desligados aleatoriamente nesse ciclo de treinamento. Os lotes de treinamento são os blocos de dados que a rede vai analisar antes de fazer uma modificação nos pesos da rede, para isso utilizando um número no batch size de 10, onde representa o número de imagens a serem analisadas pela rede antes de recalculer os pesos (LI 2014). O otimizador utilizado foi o ADAM para reduzir a função de custo. As funções de ativação utilizadas são a função Relu nas camadas profundas, pois é uma função não linear, onde a mesma retorna valores de entrada negativo em zero. Na última camada utilizamos a função sigmóide, visto que é um problema binário a se classificar, se o animal tem indicativo de displasia ou não. A taxa de aprendizado utilizada foi a padrão. As Redes foram treinadas por 100 épocas, as épocas é o número de repetições que a rede observa e analisa o conjunto de dados durante o treinamento.

A estrutura da rede densa em ambas foi a mesma utilizada, sendo 1 camada densa após a convolução com 32 neurônios e dropout de 40%. Os hiperparâmetros em uma rede são necessários, ajustando os mesmos, podemos aumentar a precisão e podemos reduzir o tempo de treinamento (Pina 2019).

3. RESULTADOS E DISCUSSÃO

Após a execução das redes, pegamos os melhores resultados de cada uma, para realizar a comparação dos dados obtidos. Não foi colocada nenhuma função de stop no período de treinamento, visando deixar a rede bem livre para poder possivelmente buscar um melhor resultado. A VGG 19 durante o tempo de 100 épocas, atingiu níveis de até 86,7% de acerto. A outra CNN utilizada durante o período de 100 épocas atingiu níveis de 93% de acerto. Tivemos ótimos resultados esperados, levando em consideração que redes de arquitetura CNN são redes profundas, ou seja, necessitam de uma quantidade bastante alta de dados para poder generalizar bem. Como tínhamos 190 imagens no total, não chega nem perto do número de imagens 'ideal' para se treinar uma CNN. Para obter resultados melhores, precisamos explorar mais os hiperparâmetros de ambas as redes, visto

que temos um número exorbitante de possibilidades para se explorar dentro de uma determinada rede. Averiguar se mais camadas densas poderiam vir a melhorar o resultado já esperado, além de testar quantidades de neurônios e possibilidades de quantos neurônios se desligar em cada camada. Aumentar o banco de dados de imagens, pois um número de 190 imagens ainda é considerado um dataset pequeno, ainda mais em redes com um número muito alto de parâmetros, porém ao mesmo tempo vemos que as redes conseguem generalizar bem a classificação das imagens radiológicas, se mostrando válidos o aprofundamento de estudos nessa área. Existem funções para reduzir a taxa de treinamento visando alcançar mínimos locais, sendo um dos pontos a se abordar no futuro.

Se faz necessário apagar uma parte dos parâmetros já aprendidos pela VGG19 para vermos quais resultados obteremos. Visto que se faz parte de técnicas de transfer learning aproveitar uma parte de aprendizado e reaprender outra parte. Realizar comparações de outras redes pré-treinadas como RESNET, ALEXNET por exemplo. Outro ponto importante é buscar melhores ferramentas para processamento da rede, visto que o colab na função gratuita está limitando bastante os usuários.

4. CONCLUSÕES

O presente estudo mostra que é válido a utilização de redes pré-treinadas para classificação de padrões radiológicos em displasia coxofemoral em cães. Mostrando ser importante aprofundar estudos na área para obter mais resultados.

5. REFERÊNCIAS BIBLIOGRÁFICAS

Hans, D., Liu, Q. and Fan, W. (2018). A new image classification method using CNN transfer learning and web data augmentation. *Expert Systems with Applications*, 95: 43–56.

Q. Li, W. Cai, X. Wang, Y. Zhou, D. D. Feng and M. Chen, "Medical image classification with convolutional neural network," *2014 13th International Conference on Control Automation Robotics & Vision (ICARCV)*, 2014, pp. 844-848, doi: 10.1109/ICARCV.2014.7064414.

PINA, Débora B.; NEVES, Liliene; PAES, Aline; DE OLIVEIRA, Daniel; MATTOSO, Marta. Análise de Hiperparâmetros em Aplicações de Aprendizado Profundo por meio de Dados de Proveniência. *In: SIMPÓSIO BRASILEIRO DE BANCO DE DADOS (SBBDD)*, 34. , 2019, Fortaleza. Anais [...]. Porto Alegre: Sociedade Brasileira de Computação, 2019 . p. 223-228. DOI: <https://doi.org/10.5753/sbbd.2019.8827>.