

# Avaliando Técnicas de Aprendizado Profundo para Detecção de Esquistossomose Mansonii em Imagens de Exames Parasitológicos

Rodrigo F. A. P. de Oliveira, Milla S. A. Ferro, Bruno J. T. Fernandes e Carmelo J. A. Bastos-Filho

Universidade de Pernambuco, Recife PE, Brasil,  
rfapo,carmelofilho@ecomp.poli.br

**Resumo** A Esquistossomose Mansonii é uma das Doenças Tropicais Negligenciadas com maior alcance epidêmico no mundo e uma das diretrizes da OMS é o diagnóstico prévio e célere para o mapeamento dos focos e aplicação do devido tratamento das pessoas infectadas. O processo atual para o diagnóstico ainda depende de uma análise em exames parasitológicos realizados por um ser humano em um microscópio em laboratório. A área de Reconhecimento de Padrões em imagens se apresenta como uma alternativa promissora como apoio e automatização de exames baseados em imagens, e técnicas de Aprendizado Profundo têm sido aplicadas com sucesso para este propósito. Com o intuito de automatizar este processo, é proposto neste trabalho a aplicação de métodos de aprendizado profundo para detecção de ovos de Esquistossomose, e é realizada uma comparação entre duas técnicas de aprendizado profundo, as Redes Neurais Convolucionais (CNN) e as Redes Neurais Piramidais Estruturadas (SPNN). Os resultados obtidos em uma base de dados reais indicam que as técnicas são eficazes no reconhecimento dos ovos da Esquistossomose, em que ambas obtiveram AUC (*area under the curve*) acima de 0,90, com a CNN mostrando superioridade neste aspecto. Entretanto, a SPNN mostrou ser mais rápida do que a CNN.

**Palavras-chaves:** Esquistossomose, Exames de Imagens, Reconhecimento de Padrões, Aprendizado Profundo, CNN e SPNN.


## 1 Introdução

A Esquistossomose é uma das Doenças Tropicais Negligenciadas com maior grau endêmico no mundo, segundo a Organização Mundial de Saúde (OMS) [1]. A Esquistossomose está presente em 76 países espalhados pela África, Leste do Mediterrâneo, Oeste do Pacífico, e Américas. Estima-se que 200 milhões de pessoas estão infectadas com a doença, além de 500 milhões de pessoas estarem expostas em áreas de risco [2]. No Brasil, a estimativa do número de indivíduos infectados com Esquistossomose é de 2,5 milhões de pessoas, mas este número pode chegar a 6,5 milhões por ausência de diagnóstico ou mapeamento de algumas regiões endêmicas [3][4]. Ainda há uma carência de pesquisas que realizem o mapeamento de mais regiões endêmicas no país. A pesquisa mais recente foi

realizada utilizando dados georeferenciados por pesquisadores de campo para mapear a prevalência da Esquistossomose na região Nordeste, mais especificamente na região litorânea do estado de Pernambuco [4].

O combate à Esquistossomose, segundo as definições da *London Declaration* [5], passa pela busca por novas técnicas de diagnóstico e mapeamento da doença, que sejam de fácil utilização, confiáveis e apresentem baixo custo para monitoramento e identificação de pacientes. Com isso, visa-se observar o comportamento emergente deste tipo de endemia. Técnicas computacionais e novas tecnologias de análises clínicas já são amplamente utilizadas como apoio a decisão na área médica e na detecção de várias doenças em exames de imagens.

As Esquistossomose Mansonii [3][4] é uma infecção causada pelo esquistossomo (*Schistosoma Mansonii*), um verme platelminto, parasita do homem e de alguns mamíferos marsupiais, utilizando-se da vênia porta, responsável por conduzir o sangue venoso para o fígado proveniente de vários órgãos, para transmissão do verme adulto. O diagnóstico da doença é realizado através de exame de carga parasitária coletada a partir das fezes. Para o processo de detecção e contagem dos ovos de uma amostra, utiliza-se o método Kato-Kats [3], que é considerado atualmente o padrão ouro para contagem de ovos e preparação das lâminas. Após este preparo, realiza-se um análise utilizando um microscópio óptico com um aumento da lente objetiva de 100 vezes. A contagem dos ovos de schistosoma presentes na amostra determina a carga parasitária e o grau de infecção do indivíduo. Todo o processo é realizado por um ser humano manualmente. O técnico de laboratório procura pelas seguintes características do ovo, espinho lateral (espícula), forma elipsoide irregular com duas membranas envoltórias, medindo cerca de 115  $\mu$ m de comprimento e 65  $\mu$ m de largura. A Figura 1 mostra uma imagem de um exame parasitológico com um ovo do *Schistosoma Mansonii* detectado, identificado na figura por uma borda retangular preta.



**Figura 1.** Ilustração do ovo da Esquistossomose Mansonii.

As técnicas de Aprendizado Profundo (*Deep Learning*)[10][11] são geralmente implementadas como Redes Neurais Artificiais compostas em sua arquitetura por diversas camadas hierárquicas, sendo bastante exploradas recentemente, com taxas de sucesso significativo na área de Reconhecimento de Padrões em imagens na área da saúde [6][7][8][9]. Considerando o sucesso recente destas técnicas,

o presente trabalho propõe a aplicação destas para extrair implicitamente as características importantes dos ovos de Esquistossomose, visando seu diagnóstico automático.

O restante do artigo está estruturado da seguinte forma: A Seção 2 apresenta as duas técnicas de Aprendizado Profundo utilizadas neste trabalho. A Seção 3 descreve a metodologia empregada, apresentando inclusive informações sobre a base de imagens utilizadas nos testes. A Seção 4 apresenta os resultados obtidos e a Seção 5 mostra as conclusões e possíveis trabalhos futuros.

## 2 Aprendizado Profundo

Nas últimas décadas, os processos de detecção e classificação, em aplicações de Reconhecimento de Padrões, foram geralmente implementados usando sistemas que realizam a extração explícita de características, seguidos de um classificador que decide se um objeto está presente no bloco de imagem analisado, avaliando os valores apresentados para as características pré-definidas.

Entretanto, há alguns anos foi percebido que sistemas com múltiplas camadas podem realizar de forma integrada a extração implícita das características mais relevantes e detecção de objetos. Os algoritmos de Aprendizado Profundo utilizam como base este conceito, diferenciando-se entre si pela estruturação da arquitetura, profundidade da arquitetura, os tipos de camada usados e os parâmetros de inicialização de cada modelo.

Este trabalho aborda duas técnicas de Aprendizado Profundo que têm potencial para detecção de ovos de Esquistossomose Mansonii em Imagens de Exames Parasitológicos, sendo elas as Redes Neurais Convolucionais (CNN) e as Redes Neurais Piramidais Estruturadas (SPNN). As CNNs apresentam excelentes taxas de detecção, mas são computacionalmente custosas. Enquanto que as SPNNs são tipicamente redes neurais não tão profundas, mas que apresentam taxas de reconhecimento de objetos adequadas a depender da complexidade do tipo de objeto a ser detectado, com menor custo computacional.

### 2.1 Redes Neurais Convolucionais (CNN)

As Redes Neurais Convolucionais (CNN)[11][12] são redes do tipo *feedforward* e tipicamente possuem as seguintes camadas em sua arquitetura: camadas convolucionais, camadas de subamostragem (ou *Pooling*), e camadas densas (ou *Fully-connected*), que podem ser dispostas de diversas formas a depender do problema abordado.

As camadas convolucionais são responsáveis por esparsar a entrada de dados e compartilhar os pesos das conexões com as camadas seguintes. Cada neurônio é conectado a um pequeno conjunto do vetor de entrada, ou seja, a uma pequena área específica, tendo similaridade com os campos receptivos do sistema da visão humana. Neurônios distintos da camada convolucional respondem por áreas diferentes do vetor de dados de entrada, sobrepondo um ao outro para obtenção

de uma melhor representação do sinal de entrada. Os nós das camadas convolucionais são agrupados em Mapas de Características com o peso compartilhado das conexões com as entradas atuando como filtros de cada camada. Este compartilhamento de pesos reduz de forma significativa o número de parâmetros da rede, aumentando a eficiência e a capacidade de generalização do modelo. Estas camadas convolucionais possuem uma função de ativação não-linear com o objetivo de capturar propriedades mais complexas do vetor de entrada.

As camadas de subamostragem, também conhecidas como *Pooling*, segmentam as entradas das camadas anteriores em agrupamentos menores, reduzindo a sensibilidade da saída às pequenas variações e nuances da entrada de dados. Geralmente, aplica-se uma função de máximo ou de média nos dados de entrada para a camada de subamostragem, a fim de evitar as variações citadas anteriormente.

Por fim, as camadas densas, também conhecidas como *Fully-connected*, são aplicadas como camada de ativação para o processo de classificação dos padrões do conjunto de entradas.

O treinamento de uma CNN é similar a outras técnicas mais simples de Redes Neurais Artificiais[13], onde há uma minimização da função de perda usando Gradiente Descendente e o erro do *backpropagation*. Desenvolver uma nova CNN para um problema específico não é trivial dada a dependência da configuração de cada camada e dos vários parâmetros com o problema em questão.

Já existem algumas arquiteturas de CNN consolidadas e aplicadas a problemas de reconhecimento de imagens, como a CifarNet [6][14], a AlexNet [6] e a GoogleLeNet [6]. Neste trabalho foi escolhida a CifarNet, dada a simplicidade da arquitetura, gerando menor esforço para a definição dos parâmetros.

## 2.2 SPNN - Redes Neurais Piramidais Estruturadas

A SPNN [15] é inspirada nas Redes Neurais Piramidais (PyraNet) [16], que por sua vez foram bioinspiradas nos conceitos de campos receptivos da visão humana.

As PyraNets possuem dois conjuntos de camadas: um conjunto de camadas 2D e um conjunto de camadas 1D. No primeiro conjunto de camadas 2D, cada neurônio está disposto em uma matriz onde cada um dos neurônios está associado a uma região da camada antecessora, chamada de campo receptivo. Na PyraNet, estes campos receptivos possuem tamanho fixo, e as camadas 2D formam uma pirâmide. A primeira camada do conjunto 2D, a base da pirâmide, é responsável por receber a imagem de entrada na rede. As outras camadas 2D são responsáveis por realizar a extração implícita das características da imagem de entrada e pela redução da dimensionalidade do modelo. O conjunto de camadas 1D é posicionada no topo da estrutura piramidal com o propósito de realizar a classificação baseada nas características extraídas pelas camadas antecessoras.

A SPNN é inspirada na PyraNet e nas redes SOM (*Self-organized Maps*), e possui uma arquitetura auto-adaptativa, flexibilizando o conceito de campo receptivo fixo. Com estas características, a SPNN reduz significativamente a quantidade de parâmetros da técnica e diminui significativamente a quantidade de recursos necessários para atingir uma boa taxa de detecção. Para a construção

dos campos receptivos irregulares, a SPNN utiliza um mapa de probabilidade gerado pelas imagens de entrada para a determinação da nuvem de pontos nos campos receptivos. Para a construção das regiões de interesse do campo receptivo, a SPNN usa a Triangulação de Delaunay [15]. A partir destas regiões, o algoritmo de clusterização *K-means*[13] agrupa os pontos de interesse, minimizando o número de neurônios das camadas adiante. Este processo se repete para as camadas seguintes até a última camada que utiliza apenas um neurônio.

Com esta arquitetura mais simples, a SPNN conseguiu resultados promissores em trabalhos anteriores [15] quando comparada a técnicas mais custosas computacionalmente, como a CNN e a SVM (*Support Vector Machine*)[13]. O treinamento da SPNN segue o mesmo modelo de treinamento de outras Redes Neurais Artificiais, como apresentado para as CNNs.

### 3 Metodologia

A proposta deste trabalho é adaptar dois modelos de Aprendizado Profundo, a CNN e a SPNN, para aplicação na detecção de ovos do *Schistosoma mansoni* em uma base de imagens reais. Em trabalhos anteriores [3], outras técnicas clássicas como Haar-like e Adaboost foram aplicadas na detecção de ovos de esquistossomose e uma acurácia de aproximadamente 80% foi obtida, sendo este valor usado como referência para os testes executados neste trabalho, assim como a metodologia de aquisição e balanceamento da base de imagens utilizadas na validação do modelo.

Esta Seção apresenta o arranjo experimental, a metodologia de pré-processamento das imagens, a descrição da base de imagens utilizada, e um estudo preliminar da influência dos parâmetros no desempenho da SPNN.

#### 3.1 Arranjo Experimental

Para esta análise comparativa, foram realizadas 30 (trinta) simulações para cada técnica proposta, além de um estudo de convergência para determinação da quantidade de épocas necessárias em cada caso.

A CifarNet foi a arquitetura de Rede Neural Convolutiva selecionada e implementada para os experimentos com CNN, por ser aplicável a problemas que envolvem a classificação com poucas classes e imagens de baixa resolução. Quando comparada a outras técnicas, como a AlexNet e GoogleNet, possui uma menor complexidade e por consequência um melhor desempenho para o tipo caso em questão.

Os parâmetros da CifarNet seguiram suas definições canônicas. Foram definidas 03 (três) camadas convolucionais, 03 (três) camadas de subamostragem e 01 (uma) camada densa, sendo a ReLU (*rectified linear unit*) utilizada como função de ativação nas camadas convolucionais e a sigmoide logística na camada densa. A CifarNet foi implementada utilizando a biblioteca Keras [17] com o suporte de *backend* para o Tensorflow [18].

A SPNN possui resultados significativos na detecção de padrões em imagens e uma acurácia similar quando comparado a técnicas mais consolidadas como a CNN e a SVM, conforme proposto por Soares *et al*[15]. Por possuir poucos parâmetros de configuração da rede e por ter sido avaliada em trabalhos anteriores com diferentes configurações em bases distintas, optou-se por avaliar o impacto e a influência de cada parâmetro na base de imagens da Esquistossomose antes da definição da melhor arquitetura. Para a análise da melhor configuração da SPNN a ser parametrizada, avaliou-se a quantidade de pontos para determinação da nuvem de pontos e o número de neurônios na primeira camada piramidal. Devido ao tempo de treinamento da SPNN ser significativamente menor quando comparado a CNN, também foi testada uma arquitetura de comitê[21] de SPNNs, com 05 (cinco) redes treinadas independentemente e decisão usando a média[21] como referência.

Todos os testes foram realizados em uma instância da EC2 (Elastic Cloud Computing) da AWS (Amazon Web Services) com um servidor Octacore Intel Xeon E-2676 2,4 GHz, com 16 (dezesesseis) GB de memória RAM e 01 (um) disco SSD de 80 GB. As implementações de todos os modelos foram desenvolvidas implementando o suporte a multithread objetivando o paralelismo nos núcleos do processador do servidor.

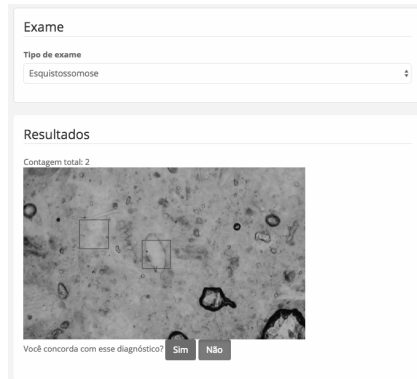
Os desempenhos das configurações testadas são apresentados utilizando a curva ROC (*receiver operating characteristic*) que relaciona a taxa de verdadeiros positivos sobre a taxa de falsos positivos. A acurácia na curva ROC é determinada por sua AUC (*area under the curve*). Para esta base, a taxa de verdadeiros positivos representa a quantidade de ovos de schistosoma detectados sobre o total de imagens positivas na base. Assim como a taxa de falsos positivos representa o número de artefatos detectados de forma incorreta, e dado como positivo, dividido pela quantidade de imagens negativas na base.

### 3.2 Preparação dos Dados e Descrição da Base de Imagens

Antes da execução do presente trabalho, não havia na literatura um banco de imagens público da Esquistossomose disponível para avaliação. No trabalho desenvolvido por Firmo *et al*[3], foi construído o Schistosystem, um software para aquisição de imagens de ovos de schistosoma em lâminas de laboratório. Em cooperação com autor do Schistosystem, foi desenvolvido o sistema Pickcells[22], como evolução do trabalho de pesquisa anterior. Esta plataforma é capaz de realizar a detecção de parasitoses em exames de imagens, além de segmentar objetos de interesse nas imagens obtidas. O Pickcells permite criar novos bancos de imagens a partir dos exames realizados.

Conforme apresentado na Figura 2, o sistema realiza a seleção do objeto de interesse através de um *bounding box* e após a validação do diagnóstico no sistema, gera-se uma imagem com as coordenadas da localização do objeto vinculados a um arquivo de log, responsável por armazenar estas informações. Utilizando-se estas imagens e o arquivo de log contendo as informações da posição do objeto, um *script* em *Python* foi desenvolvido para segmentação das imagens em dois grupos: positivas e negativas. As imagens positivas contemplam os ovos de

schistosoma e as negativas contemplam as imagens de plano de fundo e contém outros artefatos da imagem original. A construção do banco de imagens para os experimentos foi composta por estas imagens segmentadas.



**Figura 2.** Sistema Pickcells segmentando imagens de Ovos de Schistosoma.

Foram extraídas do sistema Pickcells 313 imagens positivas (imagens que contemplam um ou mais ovos de schistosoma) e 1048 imagens negativas, ambas com a resolução original de 320 por 240 pixels. Após esta extração, a técnica de segmentação dos objetos foi aplicada, gerando uma base de objetos positivos de 15754 imagens. A base de imagens negativas também foi balanceada, contendo 15754 imagens. A resolução de 28x28 foi adotada para todos os objetos da base, além da conversão de todas as imagens para a escala cinza.

Para validação cruzada, aplicou-se a técnica de *k-fold* para validar a generalização dos modelos aplicados, dividindo em dois conjuntos: *treino* e *teste*. O conjunto de *treino* é composto por 11029 imagens positivas e 11029 imagens negativas. No conjunto de *teste* foram incluídas 4725 imagens positivas e 4725 negativas.

### 3.3 Influência dos Parâmetros da SPNN

Antes do início dos experimentos, avaliou-se a influência dos parâmetros da SPNN para determinação de qual configuração seria comparada a técnica da CifarNet (CNN). Foram definidas empiricamente algumas configurações de neurônios na primeira camada piramidal (N1) e a quantidade de pontos iniciais da Nuvem de Pontos (NP). A quantidade de neurônios foi variada de 03 até 40 e a nuvem de pontos foi variada de 60 até 140, conforme apresentados na Tabela 1.

A configuração com 03 neurônios na primeira camada piramidal e com 60 pontos na nuvem de pontos obteve o melhor resultado. Foram realizados testes estatísticos de Wilcoxon com  $p = 0,05$ , para as configurações com 60 pontos na nuvem de pontos. Não houve significância estatística na comparação. Devido

a isto, todas análises da SPNN adotaram a configuração com 03 neurônios na primeira camada piramidal e 60 pontos para a Nuvem de Pontos, diminuindo a complexidade e o custo computacional da implementação.

**Tabela 1.** Influência da quantidade de Neurônios na Primeira Camada Piramidal (N1) e da Nuvem de Pontos (NP) da SPNN.

N1	NP	AUC
40	140	0,9141
30	140	0,9132
30	120	0,9044
30	90	0,9124
30	60	<b>0,9182</b>
20	60	0,9129
10	60	0,9113
05	60	0,9114
03	60	<b>0,9197</b>

## 4 Resultados

Para cada modelo proposto foi realizado um estudo de convergência para em função do número de iterações. Os modelos foram executados com 50, 100, 150 e 200 iterações.


A CifarNet convergiu rapidamente e os resultados são similares para todas as quantidades de iterações propostas. Apesar de ter apresentado uma AUC média de 0,965 com 150 iterações, o modelo encontrou uma maior estabilidade quando executado com 200 iterações e uma AUC média de 0,955, conforme apresentado na Figura 3. É importante observar que mesmo com 200 iterações, o modelo apresentou *outliers*, indicando instabilidade da técnica quando aplicada a base de imagens do experimento.

A SPNN estabilizou a partir de 100 iterações com uma AUC média de 0,911. Ainda assim, obteve uma AUC média de 0,913 com 200 iterações, conforme apresentado na Figura 4. É importante destacar a estabilidade deste modelo depois que ele atinge a convergência.


Os valores médios encontrados pelos modelos em função do número de iterações são apresentados na Figura 5.

Após a realização das 30 simulações, com 200 iterações para cada simulação, a CNN obteve uma AUC média de 0,955, enquanto que a SPNN obteve AUC média de 0,913. Devido ao tempo de treinamento e avaliação da SPNN ser significativamente menor quando comparado ao da CNN, foi também testado uma configuração composta por um Comitê de 5 SPNNs definidas empiricamente, para validar se haveria ganho na AUC. A determinação da acurácia no comitê






**Figura 3.** Análise de Convergência da CNN(CifarNet).



**Figura 4.** Análise de Convergência da SPNN.




**Figura 5.** Comparativo da Convergência da SPNN com a CNN(CifarNet).

de SPNNs foi determinada por **média**. Conforme apresentado na Tabela 2, esse ganho foi constatado e o Comitê de SPNNs obteve uma AUC média de 0,942. A Figura 6 apresenta o boxplot das AUCs obtidas para a SPNN, o comitê de 5 SPNNs e a CNN. É possível verificar que, apesar de um valor médio de AUC mais alto, a CNN apresenta uma quantidade maior de *outliers* quando comparada à SPNN e ao Comitê de SPNN's. O comitê de SPNN's apresentou uma maior estabilidade quando comparada com a CNN.

**Tabela 2.** Comparação de desempenho em termos de AUC para os modelos de Aprendizado Profundo abordados: SPNN, Comitê com 5 SPNNs e CNN.

Modelo analisado	AUC - média (Desvio Padrão)
SPNN	0,913 (0,0067)
Comitê com 5 SPNNs	0,942 (0,0036)
CNN (CifarNet)	0,955 (0,0103)



**Figura 6.** Comparação da AUC obtida pelos modelos SPNN, CNN(CifarNet) e Comitê de SPNN's.

A Tabela 3 mostra o tempo de treinamento para os modelos de Aprendizado Profundo abordados: SPNN, Comitê com 5 SPNNs e CNN, considerando as 30 Simulações. Pode-se perceber que a SPNN e o comitê de 5 SPNNs são 20 vezes e 2,53 vezes mais rápidas do que a CNN, respectivamente.

## 5 Conclusões e Trabalhos Futuros

Algumas contribuições deste trabalho quanto as técnicas de Aprendizado Profundo aplicadas podem ser destacadas. Tanto a CNN, quanto a SPNN, apresentaram resultados com acurácia superior a técnica de referência atual aplicados ao diagnóstico da esquistossomose.

**Tabela 3.** Tempo de Treinamento dos Modelos de Aprendizado Profundo abordados: SPNN, Comitê com 5 SPNNs e CNN considerando para 30 Simulações.

Modelo	Tempo de Treinamento
SPNN	01h23min
Comitê com 5 SPNNs	10h58min
CNN(CifarNet)	27h43min

O modelo da CNN analisada, a CifarNet, utilizada amplamente na literatura em aplicações de reconhecimento de padrões em imagens, obteve uma acurácia relevante quanto a detecção dos ovos nas imagens do experimento. Apesar da instabilidade, a velocidade de convergência foi o fator positivo quanto a aplicação desta técnica nos experimentos.

A SPNN, técnica aplicável na detecção de padrões em imagens, apresentou resultados promissores, além de ter obtido uma estabilidade maior quando comparada com a CNN. Por ter obtido um desempenho melhor no treinamento e na validação, quando comparada com a CNN, a implementação de um experimento contemplando um comitê com 5 SPNNs garantiu um incremento na acurácia e uma maior estabilidade, mesmo quando comparada com a configuração de uma simples SPNN e com a CNN.

Devido à simplicidade da técnica e o menor custo computacional, as SPNNs, quando utilizada em um comitê, apresentam características relevantes para ser embarcada em alguma tecnologia de baixo custo. Com isto, a tecnologia pode ser utilizada em escala na detecção da Esquistossomose, o que atenderia a um dos requisitos dos Objetivos do Milênio quanto à erradicação desta doença.

As propostas para trabalhos futuros são de aprofundar o estudo das duas técnicas quanto a outros parâmetros ou definições de arquitetura das redes, visando observar se há a possibilidade de melhoria da própria acurácia. Também há a necessidade de comparar as técnicas avaliadas com outros modelos não profundo, como a SVM, por exemplo, a fim de realizar estudos mais abrangentes desta aplicação. Ainda é necessário um estudo quanto ao desempenho e adequação destas técnicas para implementação em sistemas embarcados, objetivando o desenvolvimento de alguma ferramenta de apoio para melhorias no processo de análises clínicas na detecção da esquistossomose. Outra possibilidade é expandir as técnicas propostas para a detecção de outras geohelmintoses e doenças negligenciadas, validando a generalização dos modelos utilizados.

## Referências

1. OMS, “Trabalhando para superar o impacto global de doenças tropicais negligenciadas,” Oms, vol. 51, no. 5, pp. 247–253, 2010.
2. Scholte, Ronaldo GC, et al. ”Predictive risk mapping of schistosomiasis in Brazil using Bayesian geostatistical models.” *Acta tropica* 132 (2014): 57-63.

3. Firmo, A. C., et al. "Schistosystem-inteligencia artificial para diagnostico automatico por imagens." Atas da Conferencia IADIS Ibero-Americana Computacao Aplicada. 2013.
4. Barbosa, Constança Simões, et al. "Epidemiologia da esquistossomose no litoral de Pernambuco." Revista de Patologia Tropical 43.4 (2014): 436-445.
5. Hotez, Peter J., et al. "Eliminating the neglected tropical diseases: translational science and new technologies." PLoS neglected tropical diseases 10.3 (2016): e0003895.
6. Shin, Hoo-Chang, et al. "Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning." IEEE transactions on medical imaging 35.5 (2016): 1285-1298.
7. Min, Seonwoo, Byunghan Lee, and Sungroh Yoon. "Deep learning in bioinformatics." Briefings in bioinformatics (2016): bbw068.
8. Anthimopoulos, Marios, et al. "Lung pattern classification for interstitial lung diseases using a deep convolutional neural network." IEEE transactions on medical imaging 35.5 (2016): 1207-1216.
9. Li, Qing, et al. "Medical image classification with convolutional neural network." Control Automation Robotics & Vision (ICARCV), 2014 13th International Conference on. IEEE, 2014.
10. Rusk, Nicole. "Deep learning." Nature Methods 13.1 (2016): 35.
11. Szegedy, Christian, et al. "Going deeper with convolutions." Proceedings of the IEEE conference on computer vision and pattern recognition. 2015.
12. LeCun, Yann, Koray Kavukcuoglu, and Clément Farabet. "Convolutional networks and applications in vision." Circuits and Systems (ISCAS), Proceedings of 2010 IEEE International Symposium on. IEEE, 2010. Symp. Circuits Syst. Nano-Bio Circuit Fabr. Syst., pp. 253–256, 2010.
13. Bishop, Christopher M. Pattern recognition and machine learning. springer, 2006.
14. Krizhevsky, Alex, and Geoffrey Hinton. "Learning multiple layers of features from tiny images." (2009).
15. Soares, A. M., Fernandes, B. J., and Bastos-Filho, C. J., "Structured Pyramidal Neural Networks", International Journal of Neural Systems, p. 1750021, 2017.
16. Dodwell, Peter Carpenter. Visual pattern recognition. Holt, Rinehart and Winston, 2007.
17. Chollet, François. "Keras." (2015).
18. Abadi, Martín, et al. "Tensorflow: Large-scale machine learning on heterogeneous distributed systems." arXiv preprint arXiv:1603.04467 (2016).
19. Krizhevsky, Alex, Ilya Sutskever, and Geoffrey E. Hinton. "Imagenet classification with deep convolutional neural networks." Advances in neural information processing systems. 2012.
20. Szegedy, Christian, et al. "Rethinking the inception architecture for computer vision." Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016.
21. Polikar, Robi. "Ensemble based systems in decision making." IEEE Circuits and systems magazine 6.3 (2006): 21-45.
22. Firmo, A. C. A. et al. "Pickcells – Solução em diagnóstico parasitológico por visão computacional em imagens de lâminas de microscopia óptica". In Congresso de Medicina Tropical, 2017, Cuiabá, MT. Resumo... Centro de Eventos do Pantanal MT, 2017 p.1