

Gabriel Garcez Barros Sousa

# **Deep Learning para a Detecção e Classificação de Pneumonia por Radiografias do Tórax**

São Luís - MA

Dezembro - 2018

Gabriel Garcez Barros Sousa

Deep Learning para a Detecção e Classificação de Pneumonia por Radiografias do Tórax/ Gabriel Garcez Barros Sousa. – São Luís - MA, Dezembro - 2018-  
43p. : il. (algumas color.) ; 30 cm.

Orientador: Vandécia Rejane Monteiro Fernandes

Monografia II – Curso de Ciência da Computação  
UFMA  
, Dezembro - 2018.

1. Pneumonia. 2. Rede Neural Convolucional. 3. Radiografia. 4. Detecção 5. Classificação I. Vandécia Rejane Monteiro Fernandes. II. Universidade Federal do Maranhão. III. Deep Learning para a Detecção e Classificação de Pneumonia por Radiografias do Tórax

Gabriel Garcez Barros Sousa

# **Deep Learning para a Detecção e Classificação de Pneumonia por Radiografias do Tórax**

Monografia apresentada ao curso de Ciência da Computação da Universidade Federal do Maranhão, como parte dos requisitos necessários para obtenção do grau de Bacharel em Ciência da Computação.

Curso de Ciência da Computação

UFMA

Orientador: Vandécia Rejane Monteiro Fernandes

São Luís - MA

Dezembro - 2018

Gabriel Garcez Barros Sousa

## Deep Learning para a Detecção e Classificação de Pneumonia por Radiografias do Tórax

Monografia apresentada ao curso de Ciência da Computação da Universidade Federal do Maranhão, como parte dos requisitos necessários para obtenção do grau de Bacharel em Ciência da Computação.

Data de aprovação: 18/12/2018



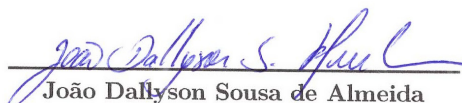
---

**Vandécia Rejane Monteiro Fernandes**  
Orientador  
Universidade Federal do Maranhão



---

**Geraldo Braz Junior**  
Examinador  
Universidade Federal do Maranhão



---

**João Dallyson Sousa de Almeida**  
Examinador  
Universidade Federal do Maranhão

São Luís - MA  
Dezembro - 2018

*To all the used up braincells.*

# Agradecimentos

Aos meus pais por toda paciência e amor dado para mim ao longo de literalmente tudo.

A Barbara por conseguir me aturar e oferecer ajuda, apoio e felicidade em todas as situações.

Aos meus grandes amigos, mesmo distantes, Alexandre, Thalles, Thiago, Nhi e Nate pelas horas incontáveis passadas juntos.

A professora Vandécia por ter oferecido orientação e direção nesses meus últimos semestres.

Aos professores que cruzaram caminho comigo, por todos os ensinamentos e experiências necessárias para o meu crescimento acadêmico.

Aos meus amigos Artur, Alexandre, André, Guilherme, José Paulo, Hannah e Wendell pelas horas de lazer necessárias fora (e dentro) da universidade.

Aos meus amigos do programa Ciências Sem Fronteiras que eu nunca esquecerei.

A todos que não foram citados mas que diretamente ou indiretamente me ajudou a chegar aqui.

*“No crying until the end.”*  
*- Mother 1, 1989*

# Resumo

Um dos exames mais comuns realizados em hospitais é a radiografia do tórax. Do resultado deste exame podem ser diagnosticadas muitas doenças, como a Pneumonia, que é a doença mais mortífera em crianças. Neste contexto, o principal objetivo deste trabalho é propor um modelo de rede neural convolucional que realiza a detecção e classificação desta doença através da radiografia do tórax. A arquitetura da rede neural convolucional é automaticamente gerada por meio de otimização de hiperparâmetros. As redes geradas foram treinadas e validadas em uma base de imagens de radiografias que apresentam casos de pneumonia por vírus e por bactéria. A melhor arquitetura encontrada para a detecção resultou em uma acurácia de 95.3% e AUC de 94%, já a melhor rede para a classificação atingiu uma acurácia de 83.1% e AUC de 80%.

**Keywords:** Pneumonia. Rede Neural Convolucional. Radiografia. Detecção. Classificação.



# Abstract

One of the most common exams done in hospitals is the chest radiograph. From the results of this exam, many illnesses can be diagnosed such as Pneumonia, which is deadliest illness for children. The main objective of this work is to propose a convolutional neural network model that performs the detection and classification of pneumonia through chest radiographs. The model's architecture is automatically generated through optimization of hyperparameters. Generated models were trained and validated with an image base of chest radiographs presenting cases of viral and bacterial pneumonia. The best architecture found resulted in an accuracy of 95.3% and an AUC of 94%, while the best architecture for classification attained an accuracy of 83.1% and AUC of 80%.

**Keywords:** Pneumonia. Convolutional Neural Network. Radiography. Detection. Classification.

# Lista de ilustrações

Figura 1 – Estrutura de alvéolo normal e afetado por pneumonia . . . . .	18
Figura 2 – Radiografia do tórax de um paciente saudável . . . . .	19
Figura 3 – Radiografia do tórax de um paciente doente . . . . .	20
Figura 4 – Etapas de Processamento Digital de Imagens . . . . .	21
Figura 5 – Exemplo de segmentação . . . . .	21
Figura 6 – Espectro de cor visível . . . . .	22
Figura 7 – Modelo de cor RGB . . . . .	23
Figura 8 – Neurônio artificial . . . . .	24
Figura 9 – Neurônio artificial . . . . .	25
Figura 10 – <i>Multilayer Perceptron</i> . . . . .	25
Figura 11 – Exemplo de uma CNN . . . . .	26
Figura 12 – Exemplo de filtros de convolução . . . . .	27
Figura 13 – Exemplos de imagens da base . . . . .	29
Figura 14 – Metodologia proposta . . . . .	30
Figura 15 – Exemplo de uma curva ROC . . . . .	33
Figura 16 – Curva ROC do modelo de detecção . . . . .	35
Figura 17 – Curva ROC do modelo de classificação . . . . .	36
Figura 18 – Curvas de aprendizagem do modelo de detecção . . . . .	37
Figura 19 – Curvas de aprendizagem do modelo de classificação . . . . .	38

# Lista de tabelas

Tabela 1 – Matriz de confusão para o modelo de detecção . . . . .	34
Tabela 2 – Matriz de confusão para o modelo de classificação . . . . .	34
Tabela 3 – Resultados dos melhores modelos de classificação e detecção . . . . .	34
Tabela 4 – Arquitetura do melhor modelo encontrado para detecção . . . . .	37
Tabela 5 – Arquitetura do melhor modelo encontrado para classificação . . . . .	38
Tabela 6 – Comparação de Resultados . . . . .	39

# Lista de abreviaturas e siglas

CNN	Convolutional Neural Networks
RGB	Red, Green Blue
RNA	Rede Neural Artificial
MLP	Multilayer Perceptron
RAM	Random Access Memory
TPE	Tree-structured Parzen Estimator
ROC	Receiver Operating Characteristic
AUC	Area Under Curve

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>14</b>
<b>1.1</b>	<b>Justificativa</b>	<b>14</b>
<b>1.2</b>	<b>Objetivos</b>	<b>15</b>
1.2.1	Objetivos Específicos	15
<b>1.3</b>	<b>Organização do trabalho</b>	<b>15</b>
<b>2</b>	<b>TRABALHOS RELACIONADOS</b>	<b>16</b>
<b>3</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>18</b>
<b>3.1</b>	<b>Pneumonia</b>	<b>18</b>
<b>3.2</b>	<b>Radiografia do Tórax</b>	<b>19</b>
<b>3.3</b>	<b>Processamento Digital de Imagens</b>	<b>20</b>
3.3.1	Modelos de representação de cor	22
3.3.1.1	Conversão de RGB para escala de cinza	23
<b>3.4</b>	<b>Redes Neurais Artificiais</b>	<b>23</b>
3.4.1	Redes Neurais Convolucionais	26
3.4.1.1	Camada de Convolução	26
3.4.1.2	Camada de Subamostragem	27
3.4.1.3	MLP Completamente Conectada	27
<b>4</b>	<b>MATERIAIS E MÉTODOS</b>	<b>29</b>
<b>4.1</b>	<b>Base de imagens de radiografias</b>	<b>29</b>
<b>4.2</b>	<b>Ferramentas</b>	<b>30</b>
<b>4.3</b>	<b>Método proposto</b>	<b>30</b>
4.3.1	Pré-processamento	30
4.3.2	Busca de arquiteturas de CNN	31
4.3.3	Treino, avaliação e diagnóstico de arquiteturas	31
<b>4.4</b>	<b>Métricas de avaliação dos resultados</b>	<b>32</b>
<b>5</b>	<b>RESULTADOS E DISCUSSÕES</b>	<b>34</b>
<b>5.1</b>	<b>Apresentação dos resultados</b>	<b>34</b>
<b>5.2</b>	<b>Arquiteturas propostas</b>	<b>36</b>
5.2.1	Arquitetura para detecção de pneumonia	36
5.2.2	Arquitetura para classificação de pneumonia	37
<b>5.3</b>	<b>Comparação de resultados</b>	<b>38</b>
<b>6</b>	<b>CONCLUSÃO</b>	<b>40</b>

<b>6.1</b>	<b>Trabalhos futuros</b> . . . . .	<b>40</b>
	<b>REFERÊNCIAS</b> . . . . .	<b>41</b>

# 1 Introdução

Cerca de 450 milhões de pessoas são afetadas por pneumonia por ano, resultando em aproximadamente 4 milhões de mortes (LODHA R; PANDEY, 2013). Em 2015, a pneumonia foi responsável por 15% das mortes de crianças com idade abaixo dos 5 anos, o que a colocou como a doença infecciosa mais mortífera em crianças (ORGANIZATION, 2016). Além disso, a pneumonia ainda apresenta a tendência a causar cerca de mais de 11 milhões de óbitos infantis até 2030 (ORGANIZATION, 2018).

Os tipos mais comuns de pneumonia são as causadas por bactérias ou vírus. Essa doença pode ser tratada de maneira mais eficaz caso seja identificada prematuramente e corretamente classificada entre a patologia bacteriana ou viral. Para auxiliar o diagnóstico de pneumonia os pacientes se submetem a um exame de imagem chamado de radiografia.

O fato de existir um exame que gera uma imagem que pode descrever a presença da pneumonia torna este problema apto a automatização por meio do uso de *Deep Learning*. *Deep Learning* ou Aprendizado Profundo, é uma área de aprendizagem de máquina que se baseia em abstrair informações complexas, como imagens, por meio de profundas camadas de processamento (LECUN; BENGIO, 1995).

Um modelo que faz uso de *Deep Learning* tem a capacidade de automaticamente aprender características e classificar imagens. Essa técnica já é bastante utilizada na área médica para o diagnóstico de doenças por exames que geram imagens ou volumes. Como exemplo, *Deep Learning* foi aplicado na detecção de glaucoma (A. WELFER D., 2017), tumores cerebrais (HAVAEL, 2017) e câncer de pele (ESTEVA et al., 2017).

Com isso, este trabalho tem como objetivo apresentar um método automático para detectar a pneumonia através da radiografia do tórax por meio de *Deep Learning*. Além disso, a técnica será utilizada para tentar diferenciar o tipo de pneumonia que afeta o paciente.

## 1.1 Justificativa

O diagnóstico de pneumonia é um processo que somente pode ser confirmado por médicos e que pode resultar em diagnósticos diferentes dependendo do especialista. Realizar uma radiografia do tórax é um ato comum em hospitais, sendo que diariamente são geradas imagens que devem ser minuciosamente analisadas por esses médicos (KELLY, 2012).

Pela grande quantidade de radiografias e pacientes presentes no mundo, a automação ou aceleração no processo de diagnóstico é algo desejável, então o uso de métodos computacionais deve ser estudado. O uso desses métodos podem diminuir a carga de

trabalho dos especialistas e ainda oferecer uma segunda opinião, aumentando a quantidade de diagnósticos precisos e rápidos.

## 1.2 Objetivos

O objetivo deste trabalho é propor um método automático para discernir entre radiografias de tórax afetados por pneumonia e radiografias saudáveis, utilizando técnicas de aprendizagem de máquina profunda para criar um modelo classificatório.

### 1.2.1 Objetivos Específicos

- Estudar e aplicar o uso de redes neurais convolucionais e otimização de hiper parâmetros para classificar radiografias do tórax;
- Realizar a classificação entre pacientes saudáveis e pacientes afetados por pneumonia;
- Realizar a classificação de pneumonia bacteriana e viral de radiografias com a patologia;
- Avaliar o funcionamento e acurácia dos modelos encontrados com bases de imagens de radiografias do tórax.

## 1.3 Organização do trabalho

Este trabalho está organizado em 5 capítulos: o Capítulo 2 apresenta os trabalhos relacionados ao assunto de classificação de pulmões afetados por pneumonia, o Capítulo 3 caracteriza a fundamentação teórica necessária para o entendimento do projeto. Esse capítulo está dividido em 4 seções, onde a primeira seção define a patologia a ser trabalhada, a segunda seção explica como funciona o exame da radiografia do tórax, a terceira e quarta seções definem o funcionamento do processamento de imagens e de redes neurais artificiais.

O Capítulo 4 apresenta a metodologia utilizada durante o projeto junto com as técnicas empregadas. No Capítulo 5, são apresentados e discutidos os resultados, comparando-os com outros estudos na literatura e finalmente, o Capítulo 6 conclui o trabalho com as considerações finais e sugestões de trabalhos futuros.



## 2 Trabalhos Relacionados

Neste Capítulo são descritos trabalhos que utilizaram técnicas computacionais para determinar a presença de pneumonia em pacientes.

[Chapman et al. \(2001\)](#) testou o desempenho de três classificadores para realizar o diagnóstico de pneumonia através de relatórios médicos. As informações presentes nesse relatório eram explicações detalhadas da radiografia do tórax, junto com alguns sintomas que o paciente estava exibindo. Os resultados foram altamente satisfatórios, apresentando uma AUC de 94% para o pior classificador. Apesar dos resultados altos, a praticidade desta técnica é baixa pelo fato de ainda necessitar tempo do especialista descrever por completo as informações necessárias para realizar a classificação.

O trabalho de [Heckerling et al. \(2004\)](#) também fez uso de exames médicos para realizar a detecção automática de pneumonia, mas se diferencia da forma que as informações foram codificadas. Os dados não eram informações detalhadas do estado do pulmão, mas sim informações binárias sobre presença de sintomas. A técnica utilizada para realizar a classificação foi de redes neurais artificiais. Este trabalho também fez uso de algoritmos genéticos para automaticamente gerar uma arquitetura da rede. O resultado deste trabalho apresentou valores altos de 94% de AUC em exames de teste.

Já o trabalho de [Oliveira et al. \(2008\)](#) somente utilizou radiografias do tórax para realizar a detecção. A base infelizmente não foi disponibilizada publicamente, mas ela foi coletada de 22 hospitais diferentes e rotulado por especialistas. A extração de características desse trabalho foi feito por diversos tipos de *wavelets* diferentes e a classificação ocorreu por dois métodos diferentes. Os testes foram realizados em somente 20 radiografias e a melhor combinação de *wavelet* e método de classificação resultou em um AUC de 97%.

Continuando com métodos que somente utilizam a radiografia para efetuar a detecção, [Rajpurkar et al. \(2017\)](#) utiliza redes neurais convolucionais para realizar a extração automática de características e a classificação. A base utilizada por este autor é pública e apresentam um total de 1,353 imagens patológicas diferentes em qualidades de imagens diferentes. O autor atingiu uma AUC de 76.8% com esta técnica.

Um dos trabalhos mais recentes nesta área pertence ao ([KERMANY et al., 2018](#)). Esse trabalho também faz uso de somente radiografias e de aprendizagem por redes neurais convolucionais, mas apresenta uma base de dados mais robusta e detalhada, apresentando 3,883 imagens. Os resultados desse trabalho foram excelentes, apresentando uma AUC de 96.8% para a detecção de pneumonia e 90.7% na diferenciação de tipo de pneumonia.

O trabalho a ser apresentado continuará a exploração de redes neurais convolucionais

---

para a extração de características e classificação automática de radiografias do tórax, mas com o diferencial de automatizar a geração da arquitetura desta rede, similar ao trabalho de [Heckerling et al. \(2004\)](#).

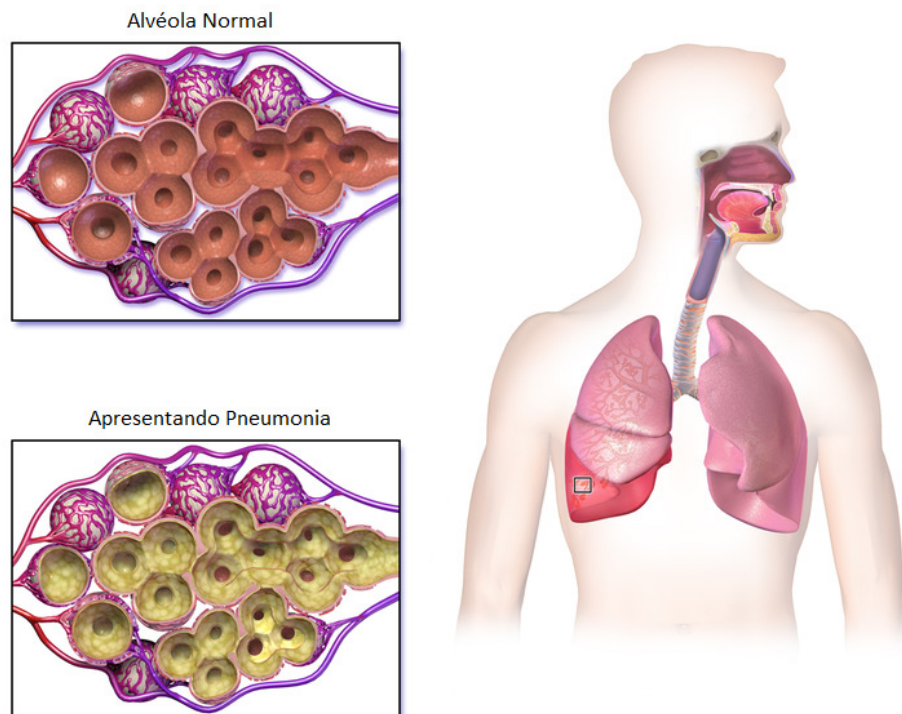
## 3 Fundamentação Teórica

Este Capítulo tem como objetivo descrever os fundamentos da pneumonia, radiografia e técnicas computacionais para o entendimento do trabalho.

### 3.1 Pneumonia

Cada pulmão é constituído por várias cavidades chamadas de alvéolos. Essas cavidades são responsáveis pela respiração e troca gasosa em um ser saudável. A pneumonia é uma doença infecciosa que inflama os alvéolos, resultando em pus e outros fluidos tomando posse dos órgãos. Os principais sintomas causados por isso são dores na respiração e diminuição da quantidade de oxigênio que o afetado consegue absorver. Tais sintomas são letais em pacientes com sistema imunológico frágil ou em ambientes precoces para a respiração.

Figura 1 – Estrutura de alvéolo normal e afetado por pneumonia



Fonte - (DOVEMED, 2016)

Os dois maiores transmissores de pneumonia são os vírus e as bactérias, e quem apresenta maior risco de ser afetado são crianças abaixo de 5 anos de idade e idosos acima de 65 anos. A pneumonia pode ser transferida por meio de fluidos expelidos por um

indivíduo infectado (INFO, 2017). A versão bacteriana da doença requer atenção agilizada por ter que ser tratada por antibióticos, enquanto a versão viral é tratada por cuidados intensivos (D GOLDBAUM M, 2018), então a diferenciação dos dois tipos da doença é altamente benéfico ao tratamento.

Diagnosticar a pneumonia é um trabalho realizado por especialistas e que geralmente requer o uso de radiografias do tórax junto com o histórico médico do paciente. A radiografia do tórax será detalhada na seção a seguir.

## 3.2 Radiografia do Tórax

O tipo de exame mais utilizado para a detecção de anomalias no coração e pulmão é a radiografia do tórax, também conhecido como raio-X do tórax. O procedimento não invasivo é realizado por radiógrafos e gera uma projeção gráfica do tórax do paciente através do uso de raios X (KELLY, 2012). Essa projeção é de fácil aquisição e substituiu o exame físico por especialistas de pulmão. Um exemplo desse exame para um paciente saudável pode ser visto na Figura 2.

Figura 2 – Radiografia do tórax de um paciente saudável




Fonte - (D GOLDBAUM M, 2018)

A análise da radiografia consiste no estudo da mesma com o objetivo de encontrar anomalias presentes na região. As anomalias variam por doença e se manifestam de diversas formas, como pontos no pulmão, tamanhos de órgãos alterados, etc (KELLY,

2012). Um diagnóstico preciso de uma radiografia requer bastante observação e experiência do especialista e esse fato pode resultar em diagnósticos diferentes para a mesma imagem.

Em uma radiografia, a pneumonia se manifesta como manchas brancas em lugares que deviam ser mais escuras. Isso se dá pelo fato dos raios X não conseguirem atravessar o pulmão por completo, sendo em parte absorvido pelos líquidos acumulados no pulmão (PARVEENA, 2011). Um exemplo de um exame de um paciente afetado pela pneumonia pode ser visto na Figura 3.

Figura 3 – Radiografia do tórax de um paciente doente



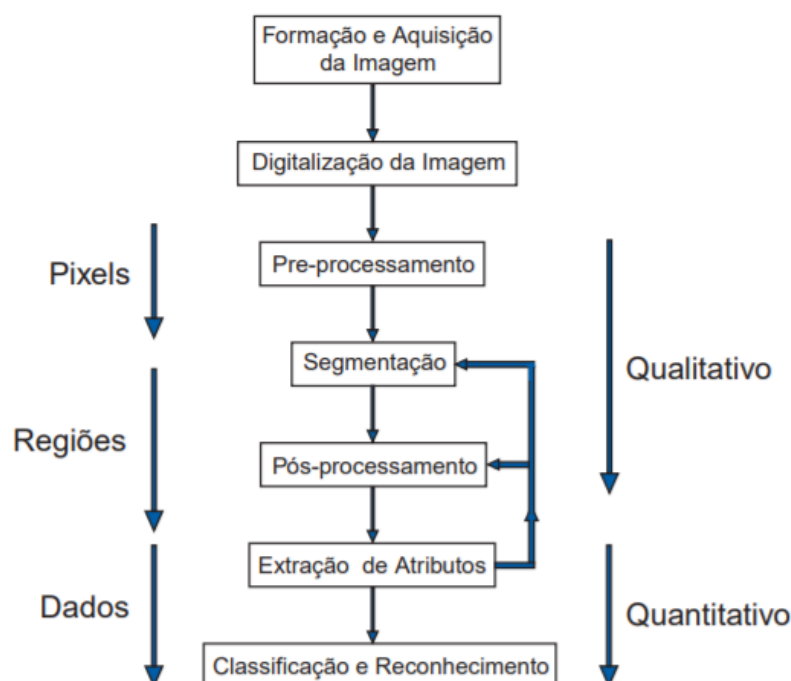
Fonte - (D GOLDBAUM M, 2018)

### 3.3 Processamento Digital de Imagens

Uma imagem digital é a representação bidimensional de um objeto ou cena por meio de dados discretos. Esses dados são codificados por uma função  $f(x, y)$  onde  $x$  e  $y$  são coordenadas espaciais e a aplicação delas em  $f$  são a proporção de luminância na imagem. Um *pixel* é a menor unidade de uma imagem e é uma representação visual da função  $f(x, y)$  (ESQUEF MÁRCIO PORTES DE ALBUQUERQUE, 2003). Um sistema que trabalha sobre essas imagens digitais faz uso de técnicas de processamento de imagens digitais. A Figura 4 explicita as usuais etapas presentes nesse processamento.

Primeiramente a imagem é adquirida por algum instrumento com sensibilidade ao espectro luminoso e que consiga converter o sinal analógico em um sinal digital. Após essa digitalização, o pré-processamento ocorre. Esse passo implica em preparar a imagem para

Figura 4 – Etapas de Processamento Digital de Imagens



Fonte - (ESQUEF MáRCIO PORTES DE ALBUQUERQUE, 2003)

melhor caber na situação exigida, o que pode resultar na conversão do tipo de imagem em outro tipo, do redimensionamento da imagem, redução de ruído da imagem e etc.

As etapas de segmentação e pós-processamento são onde informações da imagem são separadas da imagem original, seja automaticamente ou manualmente. A Figura 5 mostra uma imagem junto com dois exemplos de segmentação automático sobre esta imagem.

Figura 5 – Exemplo de segmentação



Fonte - (ESQUEF MáRCIO PORTES DE ALBUQUERQUE, 2003)


A etapa final do processo é a realização da extração de atributos ou características significativas da imagem para a classificação ou reconhecimento dela. Essa parte utiliza algoritmos para extrair informações que definem a imagem, mas de forma interpretável

pelo sistema computacional. Com essas informações o sistema pode determinar a que classe que a imagem pertence, o que é justamente o objetivo deste trabalho.

### 3.3.1 Modelos de representação de cor

A visão de um objeto é dada pela luz refletida do mesmo penetrando e ativando órgãos fotorreceptores. Já a cor deste objeto é dada pelo comprimento das ondas eletromagnéticas que são refletidas deste objeto. O espectro visível pelo olho humano varia de 390 nanômetros, que representa a cor violeta, até 750 nanômetros, que representa a cor vermelha (FRERY; PERCIANO, 2013).

Figura 6 – Espectro de cor visível



Fonte - (SOUTO, 2000)


Existem quatro atributos principais para caracterizar a luz: brilho, luminância, fluxo luminoso e intensidade luminosa. Para a escala de cinza, o atributo de brilho é o único utilizado, pois esse atributo somente varia de preto até branco. Já para o com esquema de cores, todos os atributos são utilizados (FRERY; PERCIANO, 2013).

Para representar todas essas grandezas digitalmente, existem os modelos de representação de cor, sendo um dos mais comuns o modelo RGB (Do inglês *Red, Green, Blue*). Esse modelo realiza a mistura das cores vermelho, verde e azul em quantidade diferentes para reproduzir outras cores.

Esse esquema usualmente faz uso de 256 valores diferentes para cada cor, onde 0 representa a ausência daquela cor e 255 a intensidade máxima da cor. Essa forma de representação tridimensional gera um cubo que pode ser representada em coordenadas cartesianas, que pode ser visto na Figura 7.

Como pode ser visto, a cor preta se localiza na origem no sistema cartesiano e a cor branca, no ponto extremo do cubo. O diagonal formado por estes dois pontos é a dita escala de cinza neste modelo de cor. Já as cores primárias (Vermelho, verde e azul) e secundárias (Magenta, Ciano e Amarelo) se apresentam nos outros cantos do cubo (FRERY; PERCIANO, 2013).

Figura 7 – Modelo de cor RGB



Fonte - (SOUTO, 2000)

### 3.3.1.1 Conversão de RGB para escala de cinza

A conversão do modelo de cores RGB para a escala de cinza é realizada através da extração da luminância de uma imagem RGB. Para isso, se aplica uma média ponderada sobre cada triplo RGB de uma imagem. Os valores da média ponderada está na Equação 3.1 onde  $C_R$ ,  $C_G$  e  $C_B$  correspondem aos valores da intensidade das cores vermelho, verde e azul (LINDBLUM, 2013).

$$\text{Luminância} = C_R * 0.299 + C_G * 0.587 + C_B * 0.114 \quad (3.1)$$

## 3.4 Redes Neurais Artificiais

O cérebro humano é composto por mais de 10 bilhões de células denominadas neurônios, que estão continuamente interagindo com outros neurônios por meios de impulsos chamados de sinapses. O neurônio recebe um ou mais impulsos e, dependendo da forma de recebimento, podem passar o próprio impulso para um outro neurônio. Essa rede imensa de neurônios, junto com as trocas de sinapses é como o cérebro humano realiza as suas funções (ABRAHAM, 2005).


Redes Neurais Artificiais (RNA) são modelos computacionais de aprendizagem de máquina que utilizam redes neurais biológicas como inspiração. Essas redes possuem a capacidade de realizar reconhecimento de diversos tipos de padrões em sons, imagens,



vídeos e outros (ABRAHAM, 2005).

A Figure 8 descreve a unidade básica de uma RNA, chamado de neurônio artificial.

Figura 8 – Neurônio artificial



Fonte - (SILVA; SCHIMIDT, 2016)

Como pode ser visto, o neurônio é composto de vários elementos, sendo o primeiro, os sinais de entrada. Esses sinais são valores que são transferidos para o neurônio por outros neurônios ou pelo dado sendo processado pelo modelo na entrada (ABRAHAM, 2005).

Esses sinais são multiplicados por pesos sinápticos diferentes, valores que são ajustados ao longo do processo de aprendizagem do modelo. Após dessa multiplicação, os valores são somados junto com o *bias*, também chamado de limiar, que é um valor ajustável pela aprendizagem que diminui a dependência do neurônio com relação aos outros, aumentando a possibilidade de adaptação da rede (ABRAHAM, 2005).

Após a soma, o resultado é depois aplicado a uma função não linear dita função de ativação. O valor de saída dessa função corresponde ao valor de saída do neurônio. Com isso, um neurônio artificial pode ser representado matematicamente pela Equação 3.2 onde  $y$  corresponde ao valor de saída do neurônio,  $x$  ao valor de entrada,  $w$  ao valor do peso e  $b$  ao valor do *bias*:


$$y_k = \varphi\left(\sum_{i=1}^m x_i w_{ki} + b_k\right) \quad (3.2)$$

Existem muitas funções de ativação diferentes, e algumas das mais aplicadas na

literatura podem ser vistas na Equação 3.3 com seus gráficos equivalentes na Figura 9:

$$Y^{Linear} = X \quad Y^{Sigmoid} = \frac{1}{1 + e^{-X}} \quad Y^{ReLU} = \max(0, X) \quad (3.3)$$

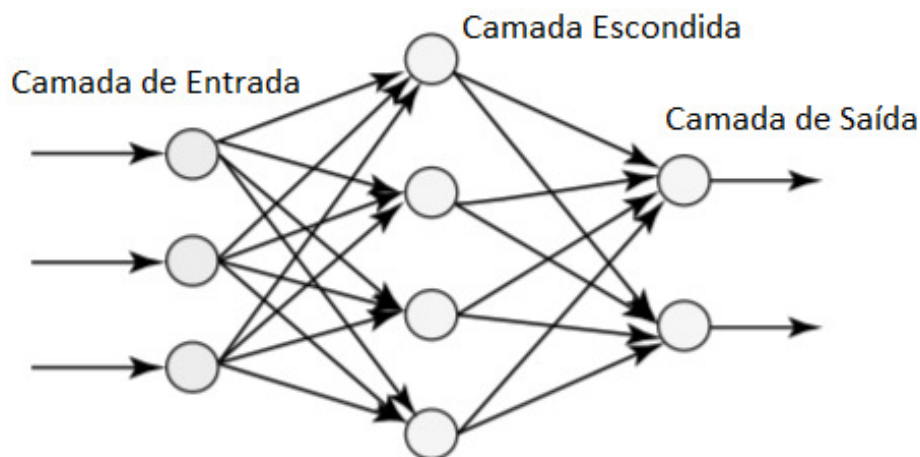
Figura 9 – Neurônio artificial



Fonte - (SILVA; SCHIMIDT, 2016)

Um neurônio não é o suficiente para solucionar problemas complexos, mesmo com qualquer função de ativação. Somente problemas linearmente separáveis podem ser resolvidos com isso (ABRAHAM, 2005). Devido a este fato, modelos ligando dezenas de neurônios sobre várias camadas existem, e são chamados de *Multilayer Perceptron* (MLP) (GARDNER; DORLING, 1998). A Figura 10 retrata uma arquitetura básica dessa rede.

Figura 10 – *Multilayer Perceptron*



Fonte - (ABRAHAM, 2005)

Uma MLP apresenta 3 tipos de camadas: camada de entrada, camada escondida e camada de saída. A camada de entrada é onde dados (imagens, sons, etc) codificados em valores numéricos são inseridos para a rede. A camada escondida, que pode ser composta de uma ou mais camadas, é onde os dados são processados para depois serem transferidos para a camada de saída que resultará em algum valor que caracterizará o dado processado.

A aprendizagem de uma MLP é usualmente realizada pelo algoritmo de *back-propagation*. Este algoritmo ajusta os pesos dos neurônios por meio de duas etapas. Na primeira, um conjunto de dados de treino é processado pela rede e o resultado gerado pela camada de saída é comparado com o dado original. Com a comparação, será gerado um valor denominado erro. Na segunda etapa, esse erro é propagado na direção contrária da

rede até alcançar a camada de entrada. A medida que o erro for propagado, os pesos são ajustados para minimizar o erro na próxima execução (ABRAHAM, 2005).

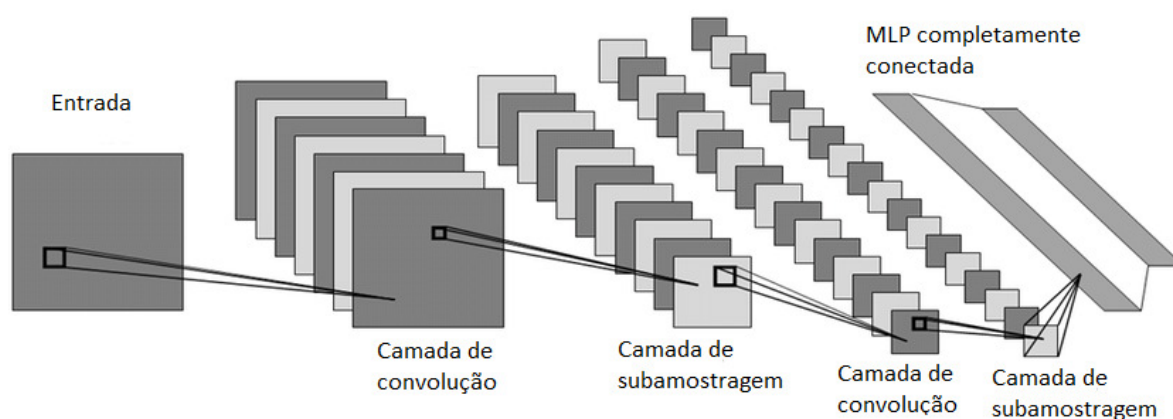
### 3.4.1 Redes Neurais Convolucionais

Aprendizagem profunda, em inglês *Deep Learning* é uma área de aprendizagem de máquina que se inspira em como a maioria dos seres vivos representam e interpretam informação visual. Humanos e animais realizam essa interpretação por meio da simplificação e abstração repetida das informações presentes em informação visual (LECUN; BENGIO, 1995).

Na aprendizagem profunda, a abstração é realizada por múltiplas camadas de aprendizagem com o intuito de cada camada assimilar representações mais simplificadas da informação ou característica sendo interpretada pelo modelo. Com essa assimilação, o modelo consegue automaticamente extrair características que definem a informação, o que reduz altamente a necessidade de pré-processamento dos dados.

O modelo de aprendizagem profunda mais usado para a aprendizagem de características de informação visual é a rede neural convolucional (CNN, do inglês *Convolutional Neural Network*). Tais redes fazem uso de camadas de convolução e subamostragem, que são as camadas de abstração automática de características das imagens. Após essas camadas, é usada uma MLP completamente conectada, tipicamente usada para realizar a função de classificação. Um exemplo de uma CNN com suas camadas é apresentada na Figura 11.

Figura 11 – Exemplo de uma CNN



Fonte - (POLETAEV; PERVUNIN; TOKAREV, 2016)

#### 3.4.1.1 Camada de Convolução

A convolução é uma forma especializada de extração de características onde um conjunto pequeno de valores, chamado de filtro, é linearmente aplicado sobre uma entrada

(YAMASHITA et al., 2018). Essa técnica é aplicada várias vezes sobre a entrada para adquirir um mapa de características que descreve a imagem. A Figura 12 demonstra 3 tipos de filtros de convolução junto com a imagem resultante da aplicação do mesmo.

A camada de convolução de uma CNN faz uso das propriedades da extração de característica de filtros, mas apresenta a diferença de filtros treináveis, ou seja, as camadas de convolução automaticamente encontram filtros que consigam extrair informação relevante das imagens utilizadas no treino do modelo (YAMASHITA et al., 2018).

Figura 12 – Exemplo de filtros de convolução

Detecção de bordas	$\begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix}$	
Nitidez	$\begin{bmatrix} 0 & -1 & 0 \\ -1 & 5 & -1 \\ 0 & -1 & 0 \end{bmatrix}$	
Desfoque	$\frac{1}{9} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}$	

Fonte - (UJJWAL, 2016)

#### 3.4.1.2 Camada de Subamostragem

As camadas de subamostragem apresentam a função de reduzir a dimensionalidade da imagem, diminuindo a sensibilidade do modelo à translações e distorções. As duas técnicas de subamostragens mais presentes na literatura são *Max Pooling* e *Average Pooling*. A primeira técnica somente mantém os *pixels* com maior intensidade da camada de neurônios anterior, enquanto a segunda técnica mantém a média dos *pixels* (LECUN; BENGIO, 1995).

#### 3.4.1.3 MLP Completamente Conectada

Após a extração automática das características, elas são transferidas para uma MLP completamente conectada que apresenta a função de classificar a imagem de entrada. Essa MLP pode ainda conter camadas de *dropout* que impedem uma quantidade aleatória de neurônios de transferir sinais entre camadas completamente conectadas. Essas camadas

têm a função de reduzir a possibilidade do modelo ficar altamente tendenciado a reproduzir o conjunto de treino em troca de um tempo maior. (KRIZHEVSKY; SUTSKEVER; HINTON, 2012).

Foram utilizadas duas CNNs na realização deste trabalho, uma para classificar entre pacientes saudáveis e não, e outra para determinar se a doença presente apresentava características de pneumonia bacteriana ou viral.

## 4 Materiais e Métodos

Neste Capítulo são descritas as ferramentas e etapas presentes na metodologia utilizada por este trabalho, detalhando a base escolhida e as ferramentas computacionais utilizadas para o desenvolvimento do método, que é explicado por inteiro na seção final.

### 4.1 Base de imagens de radiografias

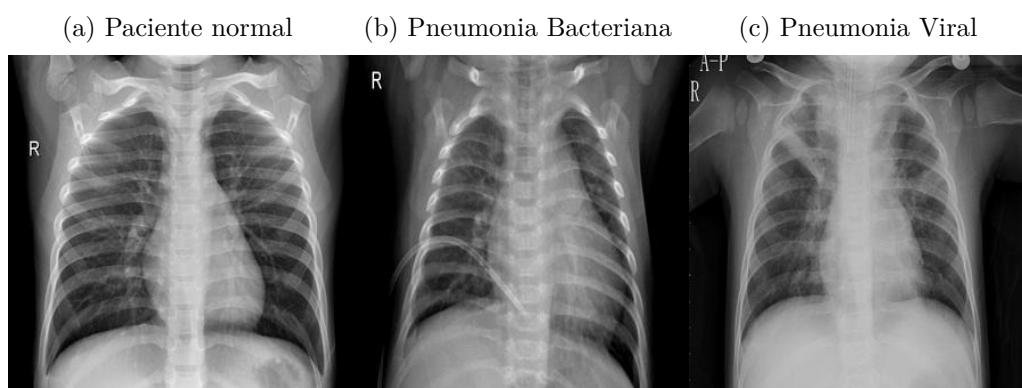
A base de imagens utilizada neste trabalho foi inicialmente coletada e marcada por [D Goldbaum M \(2018\)](#). Essa base possui 5232 imagens de radiografias do tórax coletadas de exames de rotina de crianças de 1 a 5 anos de idade do *Guangzhou Women and Children's Medical Center*. Todos os diagnósticos foram qualificados por três especialistas para evitar possíveis erros de diagnóstico.

Das 5232 radiografias, 3883 apresentam pneumonia e 1349 estão normais. Dessas 3883 imagens com a patologia, 2538 delas apresentam pneumonia bacteriana e 1345 viral. A base apresenta imagens em resoluções variadas e estão armazenadas no formato *JPEG*. Além disso, há casos de um único paciente possuindo mais que uma imagem na base e casos de radiografias inclinadas.

O autor da base separou 624 imagens da base para a realização dos testes do modelo de classificação com o cuidado de que não houvesse sobreposição de pacientes, o que criaria resultados tendenciosos. 234 das imagens separadas são de pacientes saudáveis e 390 imagens apresentam pneumonia (242 bacteriana e 148 viral). Exemplos de imagens da base podem ser vistos na [Figura 13](#).

Com isso, é perceptível que a base se apresenta adequadamente balanceada e numerosa para a realização de experimentos com redes neurais convolucionais.

Figura 13 – Exemplos de imagens da base



Fonte - ([D GOLDBAUM M, 2018](#))

## 4.2 Ferramentas

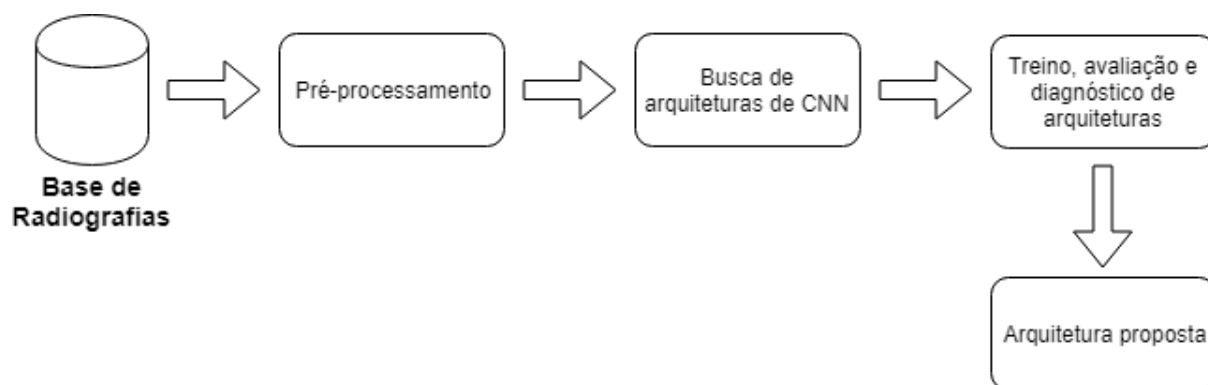
A linguagem de programação que foi utilizado para o projeto foi *Python* 3.5.2 com as bibliotecas *Hyperopt* (MAKING... , 2013) (versão 0.2), *Keras* (CHOLLET et al., 2015) (versão 2.2.4) utilizando o *backend* de *Tensorflow* (ABADI et al., 2015) (versão 1.8.0) e *Pillow* (CLARK et al., 2016) (versão 5.3.0). A criação e treino das CNNs foram realizados com as bibliotecas de *Hyperopt* e *Keras* em uma placa gráfica. A biblioteca *Pillow* foi utilizada para carregar e preprocessar as imagens.

Em termos de *hardware*, foi utilizado um computador com a seguinte configuração: processador Intel Xeon com CPU de 2.20 GHz, 13GB de memória RAM e uma placa de video Tesla K80 com 12GB de memória dedicada. O hardware foi fornecido pela plataforma Google Colaboratory (GOOGLE, 2017).

## 4.3 Método proposto

Esta seção detalha o método proposto para encontrar um modelo classificatório para o diagnóstico de pneumonias baseado em imagens de radiografias do tórax. A Figura 14 descreve os passos da proposta.

Figura 14 – Metodologia proposta



Fonte - Acervo do autor

### 4.3.1 Pré-processamento

As imagens da base se apresentam em dimensões variadas e salvas com um esquema de cor tridimensional, apesar do conteúdo da imagem estar em escala de cinza. Para corrigir isso, todas as imagens foram redimensionadas para a resolução 300x300 e salvas no formato unidimensional, para diminuir o esforço computacional necessário para o treino da rede neural convolucional.

### 4.3.2 Busca de arquiteturas de CNN

Para resolver o problema de encontrar uma arquitetura eficiente, foi utilizada a biblioteca de *Hyperopt*. Essa biblioteca apresenta a funcionalidade de estabelecer um espaço de busca e depois utilizar um algoritmo de otimização para encontrar o valor de mínimo ou máximo nesse espaço de busca.

Neste trabalho, cada elemento no espaço de busca delimitado corresponde a uma arquitetura de CNN, que inclui parâmetros contínuos (Quantidade de neurônios em cada camada) e discretos (Escolha de tamanho de filtro, taxa de *dropout* e otimizador entre opções distintas e quantidade de camadas de cada tipo). O valor que será otimizado para o máximo possível será a acurácia do modelo no conjunto de teste da base.

A delimitação de espaço de busca foi feita de tal forma que as arquiteturas experimentadas apresentavam necessidade de processamento computacional baixa, para poder encontrar modelos altamente especializadas para o problema e com aplicabilidade em computadores com poder computacional reduzido.

A função de otimização utilizada foi a *Tree-structured Parzen Estimator* (TPE), que é o algoritmo que apresentou os melhores resultados no estudo de algoritmos de otimização de hiper parâmetros realizado em [Bergstra et al. \(2011\)](#).

### 4.3.3 Treino, avaliação e diagnóstico de arquiteturas

Foram realizadas sessões de treino avaliando pelo menos 50 arquiteturas de CNN diferentes em cada sessão. As sessões foram divididas em duas classes: Uma para encontrar modelos que conseguiram detectar pneumonia entre radiografias saudáveis ou não; e a outra para encontrar modelos que classificavam radiografias patológicas entre pneumonia bacteriana e viral.

A base de treino foi dividida em treino e validação, onde a base de validação foi aplicada sobre o modelo no final de cada passada completa sobre a base de treino. As bases de treino e validação também eram equivalentes por toda uma sessão individual, esse fato permite uma comparação justa entre os resultados das arquiteturas em uma determinada sessão.

Cada arquitetura foi treinada por 100 épocas, onde uma época foi definida como a aplicação de todas as imagens no conjunto de treino sobre o modelo. Após cada época, o estado atual do modelo é validado com a base de validação e os resultados são salvos. Após as 100 épocas, o modelo testa o desempenho com a base de teste, cuja separação e quantidade foi detalhada previamente. O treino de uma sessão durava por cerca de 40 horas no total para a classe de detecção de pneumonia e 30 horas para a classe de classificação de tipo de pneumonia.



## 4.4 Métricas de avaliação dos resultados

As métricas utilizadas para a avaliação do modelo foram todas calculadas com Verdadeiro Positivo (VP), Verdadeiro Negativo (VN), Falso Positivo (FP) e Falso Negativo (FN). O verdadeiro positivo e negativo são estatísticas que mostram quando o modelo corretamente classificou classes que apresentam a doença (positivo) e não apresentam a doença (negativo). Enquanto as estatísticas de falso positivo e falso negativo denotam quando o modelo incorretamente classificou as radiografias, seja classificando um caso não apresentando a doença como apresentando (falso positivo) e o inverso (falso negativo).

As estatísticas frequentemente utilizadas na literatura para esta classe de classificação são a acurácia e a curva ROC (Do inglês, *Receiver operating characteristic*) (HAJIAN-TILAKI, 2013). Essas duas métricas, mais a de especificidade e sensibilidade foram usadas neste trabalho.

A acurácia é uma porcentagem que representa os acertos dos modelo sobre a quantidade de casos totais testados. Já a sensibilidade e especificidade mostram em porcentagem a proporção de classes verdadeiro positivas e verdadeiro negativas corretamente classificadas. As fórmula dessas 3 métricas podem ser vistas na Equações 4.1 e 4.2.

$$Acurácia = \frac{VP + VN}{VP + VN + FP + FN} \quad Sensibilidade = \frac{VP}{VP + FN} \quad (4.1)$$

$$Especificidade = \frac{VN}{VN + FP} \quad (4.2)$$


A curva ROC é um gráfico que relaciona a sensibilidade com o *fall-out*, a taxa de falso positivos no experimento. O desempenho de um modelo por meio dessa curva pode ser validado pela área sob a curva (AUC, do inglês *Area Under Curve*). Um desempenho ótimo é caracterizado pela AUC se aproximando de 1, enquanto o pior valor se aproximaria de 0.5. Qualquer valor abaixo de 0.5 significa que o resultado do classificador pode ser invertido para ter uma classificação correta. Essa métrica é bastante utilizada em classificadores de patologias na área médica, que é justamente o tema do projeto (HAJIAN-TILAKI, 2013).

As equações de sensibilidade e *fall-out* podem ser vistas em 4.3 e um exemplo de uma curva ROC apresentando uma AUC de 0.64 pode ser visto na Figura 15.

$$Fall - out = \frac{FP}{FP + VN} \quad (4.3)$$

Interpretar a curva ROC visualmente pode resultar em observações interessantes sobre o modelo estudado. A linha diagonal representa uma classificação aleatória, então quanto mais próximo da linha diagonal o canto inferior esquerdo da curva estiver, o modelo

Figura 15 – Exemplo de uma curva ROC



Fonte - Acervo do autor

está incorretamente classificando casos da primeira classe, analogamente para o canto superior direito: a classe estaria incorretamente classificando a segunda classe. Se a curva também apresentar oscilações, implica em instabilidade do modelo.

## 5 Resultados e Discussões

Neste capítulo, apresentam-se os resultados e arquiteturas de CNN obtidos com a efetuação do método proposto, e comparações com outros resultados encontrados na literatura.

### 5.1 Apresentação dos resultados

Como mencionado no capítulo anterior, as métricas utilizadas para medir a efetividade dos modelos gerados foram a acurácia, sensibilidade, especificidade e a curva ROC. Para poder gerar essas estatísticas foi primeiramente gerada a matriz de confusão do modelo com a base de testes. Essa matriz apresenta a quantidade de classes classificadas como VP, VN, FP, FN. As matrizes de confusão para os melhores modelos de detecção de pneumonia e de classificação de tipo de pneumonia podem ser vistas nas Tabelas 1 e 2.

Tabela 1 – Matriz de confusão para o modelo de detecção

		Classe Real	
		Pneumonia	Normal
Classe Prevista	Pneumonia	389	28
	Normal	1	206

Tabela 2 – Matriz de confusão para o modelo de classificação

		Classe Real	
		Bacteriana	Viral
Classe Prevista	Bacteriana	221	45
	Viral	21	103

Com as métricas calculadas, gerou-se a Tabela 3.

Tabela 3 – Resultados dos melhores modelos de classificação e detecção


	Acurácia	AUC	Sensibilidade	Especificidade
Detecção	95.3%	94%	99.7%	88%
Classificação	83.1%	80%	91.3%	69.6%

A sensibilidade para este problema demonstra a capacidade do modelo conseguir corretamente determinar quando uma radiografia apresenta pneumonia, enquanto a especificidade mostra a taxa de acerto para a quantidade de radiografias saudáveis.

Com isso, é perceptível que o modelo de detecção de pneumonia consegue resultados altamente satisfatórios pela acurácia e sensibilidade altos. A especificidade também apresenta resultados aceitáveis mas está relativamente desequilibrada em comparação com a sensibilidade, ou seja, a rede apresenta certa dificuldade em perceber as características de uma radiografia saudável.

Já para o problema de classificação, o modelo apresenta resultado sempre inferiores ao do modelo anterior. Isso mostra que a diferença entre pneumonia bacteriana e viral são consideravelmente mais sutis, portanto a rede gerada não possuiu capacidade para discernir as características de cada tipo de doença.

Figura 16 – Curva ROC do modelo de detecção




Fonte - Acervo do autor

A Figuras 16 e 17 demonstram as curvas ROC dos dois modelos encontrados. A curva para o primeiro modelo se encontra muito perto do ótimo e apresenta uma AUC alta, que é clara consequência da sensibilidade alta como já foi apresentado. Para o problema de classificação, a curva ROC se apresenta mais distante do ótimo.

Pelo fato dos valores de probabilidade geradas pelas previsões dos modelos serem valores próximos de 0 e 1, as curvas ROC vão possuir uma aparência discreta.

Figura 17 – Curva ROC do modelo de classificação



Fonte - Acervo do autor

## 5.2 Arquiteturas propostas

Nesta seção, são apresentadas as melhores arquiteturas geradas pela execução do método e suas respectivas curvas de aprendizagem. As entradas de cada modelo são imagens monocromáticas com resolução de 300 por 300 *pixels*.

### 5.2.1 Arquitetura para detecção de pneumonia

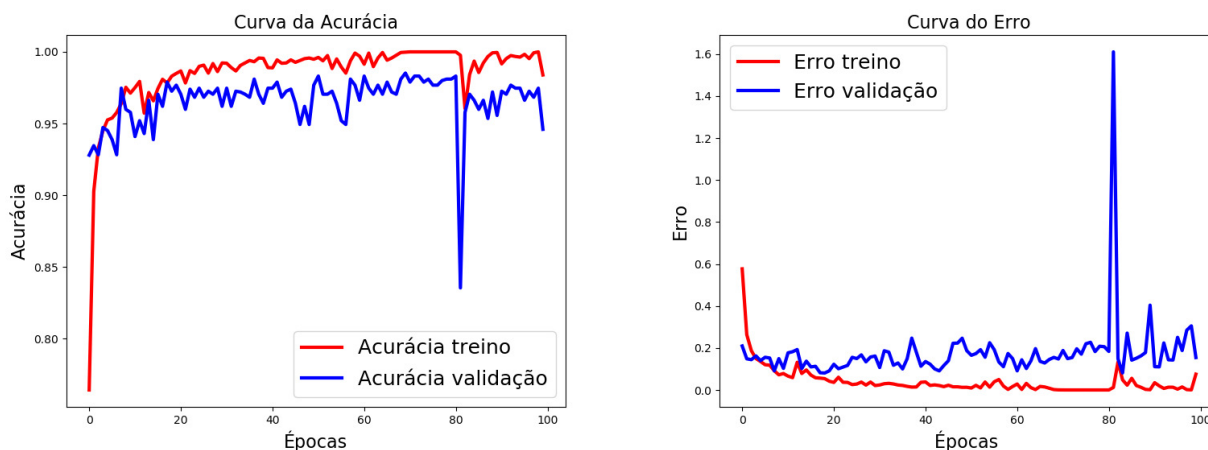
A Tabela 4 apresenta os detalhes de cada camada na arquitetura encontrada para resolver o problema de detecção de pneumonia. Deve ser ressaltado que após cada camada de MLP completamente conectada, exceto a última, o método colocou uma camada de *dropout*; com a primeira camada desse tipo apresentando um valor de 25% e o restante 50%. A função de otimização que o método selecionou para este modelo foi o RMSprop (RUDER, 2016) e o total de parâmetros que foram otimizados pelo treino foi de 717778.

Os gráficos na Figura 18 representam as curvas de aprendizagem do modelo, onde o primeiro gráfico plota a acurácia do treino e validação pelas épocas e o segundo gráfico plota o erro dos mesmos. Essas curvas produzidas pelo modelo mostram que ele rapidamente conseguiu convergir para uma resolução e conseguiu manter este valor consistentemente até um caso anômalo em torno da época 80, mas rapidamente se estabilizou após isso.

Tabela 4 – Arquitetura do melhor modelo encontrado para detecção

Tipo de Camada	Entrada	Tamanho do Filtro	Função de Ativação	Saída	Número de Parâmetros
Convolução 1	300x300x1	3x3	ReLU	150x150x16	160
Subamostragem 1	150x150x16	3x3		74x74x16	0
Convolução 2	74x74x16	3x3	ReLU	37x37x32	4640
Subamostragem 2	37x37x32	3x3		18x18x32	0
Convolução 3	18x18x32	3x3	ReLU	9x9x16	4624
Subamostragem 3	9x9x16	3x3		4x4x16	0
Convolução 4	4x4x16	3x3	ReLU	2x2x128	18560
MLP 1	512		ReLU	512	262656
MLP 2	512		ReLU	512	262656
MLP 3	512		ReLU	256	131328
MLP 4	256		ReLU	128	32896
MLP 5	128		Sigmoid	2	258

Figura 18 – Curvas de aprendizagem do modelo de detecção



Fonte - Acervo do Autor

### 5.2.2 Arquitetura para classificação de pneumonia

A arquitetura encontrada para solucionar o problema de classificação de variedade de pneumonia pode ser vista na Tabela 5. Similarmente à arquitetura anterior, toda camada após uma de MLP completamente conectada, exceto a última, apresentou uma camada de *dropout*, com a primeira e quarta apresentando uma taxa de 25%, e a segunda e terceira de 50%. A função de otimização escolhida para este modelo foi o de ADAM (RUDER, 2016) e a arquitetura apresentou um total de 526434 parâmetros para serem ajustados durante o treino.


Os gráficos produzidos durante o treino deste modelo estão presentes na Figura 19. É perceptível que a rede nunca convergiu para satisfazer a base de validação junto com o treino, ao ponto que ela aparentava divergir quanto mais a rede era treinada pelo gráfico

Tabela 5 – Arquitetura do melhor modelo encontrado para classificação

Tipo de Camada	Entrada	Tamanho do Filtro	Função de Ativação	Saída	Número de Parâmetros
Convolução 1	300x300x1	5x5	ReLU	150x150x16	160
Subamostragem 1	150x150x16	3x3		74x74x16	0
Convolução 2	74x74x16	3x3	ReLU	37x37x64	9280
Convolução 3	37x37x64	3x3	ReLU	19x19x32	18464
Subamostragem 2	19x19x32	3x3		9x9x32	0
Convolução 4	9x9x32	3x3	ReLU	5x5x128	36992
Subamostragem 3	5x5x128	3x3		2x2x128	0
MLP 1	512		ReLU	1024	525312
MLP 2	1024		ReLU	64	65600
MLP 3	64		ReLU	512	33280
MLP 4	512		ReLU	512	262656
MLP 5	512		Sigmoid	2	1026

do erro. Isto leva à grande possibilidade da rede ter caído em um mínimo local por ter ficado sobreajustada aos dados de treino.

Figura 19 – Curvas de aprendizagem do modelo de classificação



Fonte - Acervo do Autor

### 5.3 Comparação de resultados

Nesta seção, comparam-se os resultados obtidos pelo método empregado pelo projeto com outros métodos encontrados na literatura. A tabela 6 demonstra essa comparação, apresentando os valores das métricas obtidas durante os experimentos, junto com a quantidade de parâmetros no modelo empregado e a quantidade de radiografias apresentando pneumonia.

Tabela 6 – Comparação de Resultados

Tipo do Problema	Autor	Quantidade de Radiografias com Pneumonia	Acurácia	AUC	Sensibilidade	Especificidade	Número de Parâmetros
Detecção	<a href="#">Kermany et al. (2018)</a>	3,883	92.8%	96.8%	93.2%	90.1%	23 milhões
	<a href="#">Rajpurkar et al. (2017)</a>	1,353	-	76.8%	-	-	0.8 milhões
	Método Proposto	3,883	95.3%	94%	99.7%	88%	0.77 milhões
Classificação	<a href="#">Kermany et al. (2018)</a>	3,883	90.7%	94%	88.6%	90.9%	23 milhões
	Método Proposto	3,883	83.1%	80%	91.3%	69.6%	0.52 milhões

Para o problema de detecção de pneumomonia, o trabalho que apresentou o melhor resultados em termos de AUC foi de [Kermany et al. \(2018\)](#), o criador da base utilizada no projeto. Apesar do AUC alto, o método proposto atinge valores superiores em outras métricas, exceto em especificidade. A arquitetura que esse autor utilizou foi a *Inception V3* ([SZEGEDY et al., 2015](#)) que requer um longo período de treino e capacidade computacional considerável, ao contrário do modelo encontrado que apresenta 96% menos parâmetros a serem ajustados.

O autor [Rajpurkar et al. \(2017\)](#) utilizou a base *ChestX-ray14* ([WANG et al., 2017](#)), que apresentam 112,120 imagens de radiografias com somente 1,353 delas apresentando pneumonia e demais anomalias torácicas. As classificações desta base foram geradas computacionalmente por meio de processamento de linguagem natural. Essa geração apresenta uma acurácia de 88.9% para as classificações de pneumonia. Essa incerteza na nomeação de radiografias de pneumonia podem gerar modelos confusos e pode ser um dos motivos pela baixa AUC do autor.

Já para o problema de classificação entre pneumonia bacteriana e viral, o autor original conseguiu resultados sempre superiores, exceto na sensibilidade. A sensibilidade maior do método proposto pode ter sido acarretada pelo desbalanceamento de classes, o que aumenta as chances de geração de um modelo tendencioso, desde que o modelo não apresente métodos de evitar tal problema. A complexidade maior do modelo do autor consegue combater esse problema, apresentando estatísticas sempre estáveis.

Com isso, é perceptível que o método proposto consegue gerar modelos simples que são capazes de detectar pneumonia com níveis de acurácia superiores a outros trabalhos na literatura.



## 6 Conclusão

Realizar o diagnóstico de doenças através de radiografias é uma prática comum em hospitais. Este trabalho apresentou técnicas de como acelerar esse diagnóstico no caso de pneumonia. A técnica utilizada neste trabalho foi de aprendizagem profunda, que é uma técnica frequentemente utilizada para a classificação e reconhecimento de imagens na literatura.

Foram apresentadas arquiteturas possíveis para a detecção de pneumonia e a classificação dessa doença em viral ou bacteriana, utilizando radiografias do tórax. Os modelos foram encontrados por meio da otimização de arquiteturas de Redes Neurais Convolucionais através do uso da biblioteca HyperOpt.

Os resultados encontrados foram bastante satisfatórios para a detecção da doença, superando a acurácia e sensibilidade do criador da base utilizada neste trabalho e ainda apresentando uma simplicidade em termos de necessidade computacional. Esse último fato torna o modelo bastante aplicável em diversas situações. Já para a classificação da patologia, os modelos simples não conseguiram atingir a capacidade de perceber as características sutis das variedades da doença.

### 6.1 Trabalhos futuros

Como trabalhos futuros, sugere-se os seguintes tópicos:

- Explorar formas de segmentar a região do pulmão antes de realizar a etapa de treino para acelerar e facilitar a extração automática de características;
- Expandir o espaço de busca para abranger arquiteturas mais complexas e variadas e que utilizam técnicas mais avançadas como camadas de transição (THOMA, 2017);
- Explorar ou aumentar o repertório de bases de radiografias de pneumonia na literatura.

# Referências

- A. WELFER D., C. d. M. P. H. C. J. D. G. N. C. Automatic identification of glaucoma using deep learning methods. *Studies in Health Technology and Informatics*, PubMed, v. 2017, 2017. Disponível em: <<https://www.ncbi.nlm.nih.gov/pubmed/29295107>>. Citado na página 14.
- ABADI, M. et al. *TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems*. 2015. Software available from tensorflow.org. Disponível em: <<http://tensorflow.org/>>. Citado na página 30.
- ABRAHAM, A. *Artificial Neural Networks*. American Cancer Society, 2005. ISBN 9780471497394. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1002/0471497398.mm421>>. Citado 4 vezes nas páginas 23, 24, 25 e 26.
- BERGSTRA, J. et al. Algorithms for hyper-parameter optimization. Curran Associates Inc., USA, p. 2546–2554, 2011. Disponível em: <<http://dl.acm.org/citation.cfm?id=2986459.2986743>>. Citado na página 31.
- CHAPMAN, W. W. et al. A comparison of classification algorithms to automatically identify chest x-ray reports that support pneumonia. *J. of Biomedical Informatics*, Elsevier Science, San Diego, USA, v. 34, n. 1, p. 4–14, fev. 2001. ISSN 1532-0464. Disponível em: <<http://dx.doi.org/10.1006/jbin.2001.1000>>. Citado na página 16.
- CHOLLET, F. et al. *Keras*. 2015. <<https://keras.io>>. Citado na página 30.
- CLARK, A. et al. Pillow: 3.1.0. Zenodo, Jan 2016. Citado na página 30.
- D GOLDBAUM M, C. W. e. a. K. Identifying medical diagnoses and treatable diseases by image-based deep learning. *Cell*, 2018. Citado 3 vezes nas páginas 19, 20 e 29.
- DOVEMED. Viral pneumonia. Março 2016. Disponível em: <<https://www.dovemed.com/diseases-conditions/viral-pneumonia/>>. Citado na página 18.
- ESQUEF MÁRCIO PORTES DE ALBUQUERQUE, M. P. d. A. I. A. Processamento digital de imagens. Centro Brasileiro de Pesquisas Físicas, 2003. Citado 2 vezes nas páginas 20 e 21.
- ESTEVA, A. et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, Macmillan Publishers Limited, part of Springer Nature. All rights reserved., v. 542, p. 115–, jan. 2017. Disponível em: <<http://dx.doi.org/10.1038/nature21056>>. Citado na página 14.
- FRERY, A. C.; PERCIANO, T. Introduction to image processing using r. SpringerBriefs in Computer Science, 2013. Citado na página 22.
- GARDNER, M.; DORLING, S. Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. *Atmospheric Environment*, v. 32, n. 14, p. 2627 – 2636, 1998. ISSN 1352-2310. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1352231097004470>>. Citado na página 25.

- GOOGLE. Google colabory. 2017. Disponível em: <<https://colab.research.google.com/>>. Citado na página 30.
- HAIJIAN-TILAKI, K. Receiver operating characteristic (roc) curve analysis for medical diagnostic test evaluation. *Caspian journal of internal medicine*, v. 4, n. 2, p. 627 – 635, 2013. Citado na página 32.
- HAVAELI, e. a. M. Brain tumor segmentation with deep neural networks. *Medical Image Analysis*, v. 35, p. 18 – 31, 2017. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1361841516300330>>. Citado na página 14.
- HECKERLING, P. S. et al. Use of genetic algorithms for neural networks to predict community-acquired pneumonia. *Artificial intelligence in medicine*, v. 30, p. 71–84, 02 2004. Citado 2 vezes nas páginas 16 e 17.
- INFO, R. Pneumonia. 2017. Disponível em: <<https://www.radiologyinfo.org/en/info.cfm?pg=pneumonia>>. Citado na página 19.
- KELLY, B. The chest radiograph. *Ulster Medical Society*, v. 81, n. 3, p. 143 – 148, 2012. Disponível em: <<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3632825/>>. Citado 3 vezes nas páginas 14, 19 e 20.
- KERMANY, D. S. et al. Identifying medical diagnoses and treatable diseases by image-based deep learning. *Cell*, Elsevier BV, v. 172, n. 5, p. 1122–1131.e9, feb 2018. Disponível em: <<https://doi.org/10.1016%2Fj.cell.2018.02.010>>. Citado 2 vezes nas páginas 16 e 39.
- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. Curran Associates Inc., USA, p. 1097–1105, 2012. Disponível em: <<http://dl.acm.org/citation.cfm?id=2999134.2999257>>. Citado na página 28.
- LECUN, Y.; BENGIO, Y. Convolutional networks for images, speech, and time-series. *The Handbook of Brain Theory and Neural Networks*, p. 14, 01 1995. Citado 3 vezes nas páginas 14, 26 e 27.
- LINDBLUM, B. Rgb working space information. 2013. Disponível em: <<http://www.brucelindbloom.com/index.html?WorkingSpaceInfo.html>>. Citado na página 23.
- LODHA R, K. S.; PANDEY, R. Antibiotics for community-acquired pneumonia in children. *Cochrane Database of Systematic Reviews*, John Wiley Sons, Ltd, n. 6, 2013. ISSN 1465-1858. Disponível em: <<https://doi.org/10.1002/14651858.CD004874.pub4>>. Citado na página 14.
- MAKING a Science of Model Search: Hyperparameter Optimization in Hundreds of Dimensions for Vision Architectures. *ICML*, 2013. Citado na página 30.
- OLIVEIRA, L. L. G. et al. Computer-aided diagnosis in chest radiography for detection of childhood pneumonia. *International Journal of Medical Informatics*, v. 77, n. 8, p. 555 – 564, 2008. ISSN 1386-5056. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1386505607001803>>. Citado na página 16.

- ORGANIZATION, S. the C. Pneumonia to kill nearly 11 million children by 2030. 2018. Disponível em: <<https://reliefweb.int/report/world/pneumonia-kill-nearly-11-million-children-2030>>. Citado na página 14.
- ORGANIZATION, W. H. Pneumonia. 2016. Disponível em: <<http://www.who.int/news-room/fact-sheets/detail/pneumonia>>. Citado na página 14.
- PARVEENA, M. M. S. N. R. S. Detection of pneumonia in chest x-ray images. *Journal of X-Ray Science and Technology* 19, 2011. Citado na página 20.
- POLETAEV, I. E.; PERVUNIN, K.; TOKAREV, M. Artificial neural network for bubbles pattern recognition on the images. *Journal of Physics Conference Series*, v. 754, p. (072002)–13, 10 2016. Citado na página 26.
- RAJPURKAR, P. et al. Chexnet: Radiologist-level pneumonia detection on chest x-rays with deep learning. *CoRR*, abs/1711.05225, 2017. Disponível em: <<http://arxiv.org/abs/1711.05225>>. Citado 2 vezes nas páginas 16 e 39.
- RUDER, S. An overview of gradient descent optimization algorithms. *CoRR*, abs/1609.04747, 2016. Disponível em: <<http://arxiv.org/abs/1609.04747>>. Citado 2 vezes nas páginas 36 e 37.
- SILVA, S. R.; SCHIMIDT, F. Redução de variáveis de entrada de redes neurais artificiais a partir de dados de análise de componentes principais na modelagem de oxigênio dissolvido. *Química Nova*, n. 6, p. 273–278, 2016. Disponível em: <<https://dx.doi.org/10.5935/0100-4042.20160024>>. Citado 2 vezes nas páginas 24 e 25.
- SOUTO, R. P. Segmentação de imagem multiespectral utilizando-se o atributo matiz. *São José dos Campos: INPE*, abs/1711.05225, 2000. Citado 2 vezes nas páginas 22 e 23.
- SZEGEDY, C. et al. Rethinking the inception architecture for computer vision. *CoRR*, abs/1512.00567, 2015. Disponível em: <<http://arxiv.org/abs/1512.00567>>. Citado na página 39.
- THOMA, M. Analysis and optimization of convolutional neural network architectures. *CoRR*, abs/1707.09725, 2017. Disponível em: <<http://arxiv.org/abs/1707.09725>>. Citado na página 40.
- UJJWAL, K. An intuitive explanation of convolutional neural networks. 2016. Disponível em: <<https://ujjwalkarn.me/2016/08/11/intuitive-explanation-convnets/>>. Citado na página 27.
- WANG, X. et al. Chestx-ray8: Hospital-scale chest x-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases. *CoRR*, abs/1705.02315, 2017. Disponível em: <<http://arxiv.org/abs/1705.02315>>. Citado na página 39.
- YAMASHITA, R. et al. Convolutional neural networks: an overview and application in radiology. *Insights into Imaging*, v. 9, n. 4, p. 611–629, Aug 2018. ISSN 1869-4101. Disponível em: <<https://doi.org/10.1007/s13244-018-0639-9>>. Citado na página 27.