



UNIVERSIDADE FEDERAL DO MARANHÃO

Curso de Ciência da Computação

Bruno Eduardo Silva Ferreira

**Segmentação Semântica de Lesões de Pele
utilizando Redes Neurais Convolucionais**

São Luís/MA

2018

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).
Núcleo Integrado de Bibliotecas/UFMA

Silva Ferreira, Bruno Eduardo.

Segmentação Semântica de Lesões de Pele utilizando
Redes Neurais Convolucionais / Bruno Eduardo Silva
Ferreira. - 2018.

35 f.

Orientador(a): Geraldo Braz Júnior.

Monografia (Graduação) - Curso de Ciência da
Computação, Universidade Federal do Maranhão, São Luís,
2018.

1. Dermatoscopia. 2. Melanoma. 3. Redes Neurais
Convolutivas. 4. Segmentação. I. Braz Júnior, Geraldo.
II. Título.

Bruno Eduardo Silva Ferreira


**Segmentação Semântica de Lesões de Pele utilizando Redes Neurais
Convolucionais**

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. Orientador: Prof. Dr. Geraldo Braz Júnior


Trabalho aprovado em São Luís -MA, 14 de dezembro de 2018:



Prof. Dr. Geraldo Braz Júnior
(Orientador)



Profa. Dra Simara Vieira da Rocha
Examinadora 1



**Prof. MSc. Caio Eduardo Falcão
Matos**
Examinador 2

São Luís/MA

2018

Agradecimentos

Em primeiro lugar, agradeço aos meus pais, que durante 22 anos da minha vida me apoiaram com amor, motivação, carinho e tudo que foi necessário para eu chegar até aqui.

Agradeço aos meus avós, que com toda a simplicidade do mundo me ensinaram que a vida se vence nos pequenos detalhes.

Aos meus padrinhos, que incentivaram e me abraçaram durante toda a vida como se fosse um de seus filhos.

Aos meus primos: Roberto e Pablo. Que foram os irmãos que não tive e que acabaram me guiando a cursar Ciência da Computação.

Aos meus amigos do ensino médio, especialmente à formação original do Nigrinhagem: Alzy Sales Ai, Andréia, Anna Karina, Bárbara, Berebel, Bruno e Valéria. Apesar da distância, eu sei que cada um está torcendo pelo outro pelo resto da vida. Amo vocês.

Aos amigos que conheci no curso, principalmente aos Bichos Soltos. Crick, Gabriel, Hugoy, Lucas, Paulo trash, Potássio e Vitu. Nós nos ajudamos bastante nessa jornada, dentro e fora da Universidade. Nunca será igual ao que foi um dia, mas me lembrarei sempre do nosso companheirismo.

Ao PETComp, que me abraçou do segundo ao sétimo período do curso. Todas as pessoas que conheci ali foram importantes para meu crescimento acadêmico/pessoal/profissional. Aqui aprendi o conceito de cooperação. Agradecimento especial aos tutores Alexandre e Geraldo que lideraram a turma mais divertida do curso.

Aos amigos que também são do curso mas que estreitei a relação no Dota, que de alguma forma me fizeram raiva alguma vez nessas mais de 4000 horas. Vocês me ensinaram a ter paciência mais do que nunca e que sozinho não se conquista nada nessa vida. MID OR FEED!

Aos amigos que fiz no estágio: Arthur, Debs, Carol, Gio, João, Priscila e Talita. Compartilhamos risadas, dramas, segredos e companheirismo durante os dois últimos anos. Fica aqui meu agradecimento para essa Diretoria.

Aos meus amigos do Churrasco Bem Bolado, que em tão pouco tempo me fizeram crescer em todos os aspectos. Cada um de vocês foi importante na minha trajetória. Obrigado, Alulu, Cíntia, Dayson, Gabs, Helen, Lennon, Osvaldo, Pedro e Raissa.

A Hellen, que nos últimos meses me apoiou e me incentivou como ninguém. Sou muito grato pelo seu companheirismo e paciência comigo. E como prometido, um parágrafo exclusivo para mostrar meus sinceros agradecimentos.

*"Don't worry,
there's plenty to go around."*

(Storm Spirit)

Resumo

O alto índice de mortalidade em casos de câncer de pele é um fator que leva o diagnóstico precoce de Melanoma a ser um desafio para a medicina computacional. Os médicos especialistas têm algumas ferramentas que auxiliam no diagnóstico precoce desse tipo de câncer, uma dessas ferramentas é a dermatoscopia. Neste segmento, existem estudos que têm como o objetivo realizar o diagnóstico dessa doença de forma automática utilizando ferramentas da Inteligência Artificial por meio de imagens dermatoscópicas, visto que o quanto mais cedo é feita a descoberta do câncer, maiores as chances de cura. Uma etapa muito importante do processo de diagnóstico consiste na segmentação das lesões para melhor extração de características. Este trabalho tem por objetivo utilizar a rede neural convolucional U-net para segmentar imagens dermatoscópicas com o objetivo de auxiliar no processo de diagnóstico automático. Os testes foram realizados em duas bases de dados, sendo uma pública (PH2) e uma composta por imagens retiradas do repositório ISIC. Em ambas obteve-se resultados satisfatórios, obtendo uma média de Sensibilidade, Precisão e Coeficiente de Dice superior a 97%.

Palavras-Chaves: Melanoma, Segmentação, Redes Neurais Convolutivas, Dermatoscopia;

Abstract

The high mortality rate in cases of skin cancer is one factor that leads to the early diagnosis of melanoma being a challenge for computer medicine. Medical experts have some tools that help in the early diagnosis of this type of cancer, one of these tools is dermatoscopy. In this segment, there are studies that aim to diagnose this disease automatically using Artificial Intelligence tools through dermoscopic images, since the earlier the cancer is discovered, the greater the chances of cure. A very important step in the diagnosis process is the segmentation of the lesions to better feature extraction . This work aims to use the U-net convolutional neural network to segment dermoscopic images with the objective of assisting in the automatic diagnosis process. The tests were performed in two databases, one public (PH2) and one composed of images taken from the ISIC repository. In both, satisfactory results were obtained, obtaining a mean of Sensitivity, Accuracy and Dice Coefficient of over 97 %.

Keywords: Melanoma, Segmentation, Convolutive Neural Networks, Dermoscopy;

Lista de ilustrações

Figura 1 – Médico utilizando um dermatoscópio	14
Figura 2 – Exemplo de imagem dermatoscópica saudável e maligna	15
Figura 3 – Representação de um neurônio humano	16
Figura 4 – Arquitetura básica de uma Rede Neural Artificial	17
Figura 5 – Arquitetura MLP com duas camadas intermediárias.	19
Figura 6 – Uma rede neural convolucional e suas diferentes camadas	20
Figura 7 – Etapas da Metodologia Proposta.	22
Figura 8 – Imagens extraídas do dermatoscópio em cima e na parte de baixo temos a Segmentação manual realizada pelo especialista.	23
Figura 9 – Arquitetura da rede U-net.	25
Figura 10 – Curva de aprendizagem para segmentação na base PH2	29
Figura 11 – Curva de aprendizagem para segmentação na base autoral	29
Figura 12 – Exemplo de saída de uma imagem cancerosa de fácil segmentação da base autoral.	30
Figura 13 – Exemplo de saída de uma imagem cancerosa de complexidade média da base autoral.	31
Figura 14 – Exemplo de saída de uma imagem cancerosa de difícil segmentação da base autoral.	31

Lista de tabelas

Tabela 1 – Resultados da segmentação na base PH2	28
Tabela 2 – Resultados da segmentação na base Autoral	28

Lista de abreviaturas e siglas

UFMA	Universidade Federal do Maranhão
RNAs	Redes Neurais Artificiais
CNN	Redes Neurais Convolucionais
INCA	Instituto Nacional de Câncer
MLP	Perceptron de múltiplas camadas
PH2	Base de dados PH2
ISIC	Colaboração Internacional de Imagem de Pele
ReLu	Unidade Linear Retificada
IoU	<i>Intersection over Union</i>
CSD	Coefficiente de Similaridade de Dice

Sumário

	Lista de tabelas	8
1	INTRODUÇÃO	11
1.1	Objetivos	12
1.1.1	Objetivos Específicos	12
1.2	Trabalhos Relacionados	12
1.3	Estrutura do Trabalho	13
2	FUNDAMENTAÇÃO TEÓRICA	14
2.1	Dermatoscopia	14
2.2	Segmentação de imagens digitais	15
2.3	Redes Neurais Artificiais	16
2.3.1	Redes Neurais Convolucionais	19
3	METODOLOGIA	22
3.1	Materiais	22
3.2	Aquisição de dados	22
3.3	Segmentação semântica utilizando U-NET	24
3.3.1	Avaliação	26
4	RESULTADOS	28
4.1	Estudos de Casos	30
5	CONCLUSÃO	32
	REFERÊNCIAS	33

1 INTRODUÇÃO

De acordo com o Instituto Nacional de Câncer (INCA), o câncer de pele é o mais comum no Brasil, representando cerca de 30% de todos os casos de câncer no país. Um dos tipos de câncer de pele que chama mais atenção devido a seu alto grau de fatalidade é conhecido como Melanoma. O melanoma corresponde a uma lesão que se origina dos melanócitos, as células produtoras de melanina (substância responsável pela coloração de nossa pele). Apesar do Melanoma representar cerca de 95% de todas as mortes envolvendo câncer de pele, quando descoberto em seu estágio inicial, pode ser facilmente curado.

Até então não se sabe ao certo o que causa o Melanoma, porém existem fatores de risco que devem ser levados em consideração, por exemplo: exposição excessiva ao sol ao longo da vida, pele clara e com muitas pintas, incidência familiar e histórico pessoal. O melanoma pode se dar a partir de uma mancha já existente ou de uma nova lesão que nasceu espontaneamente.

O melanoma maligno é um dos tipos de câncer mais mortais que existe. Apesar disso, quando o diagnóstico e tratamento são realizados de forma precoce, as chances de curas são altas (INCA, 2018).

Caso haja suspeita da incidência do tumor, o dermatologista tem uma série de técnicas a disposição para auxiliar no diagnóstico. Uma das mais comuns é a dermatoscopia, que comumente se realiza com um aparelho denominado dermatoscópio. A dermatoscopia aumenta a acurácia do diagnóstico e ajuda na diferenciação de lesões benignas de lesões cancerosas.

As imagens dermatoscópicas têm grande potencial de diagnóstico precoce de melanomas malignos. Porém, até mesmo para médicos especialistas, realizar a segmentação dessas lesões é algo custoso e difícil, devido a grande variedade de manchas, que muitas das vezes possuem bordas irregulares, diferentes dimensões e cores. Portanto, estudos vêm sendo realizados com o objetivo de segmentar essas lesões de forma automática para auxiliar esses profissionais.

Com base nisso, este trabalho propõe o desenvolvimento de uma metodologia que tem como objetivo segmentar imagens dermatoscópicas de forma automática, de modo que os contornos extraídos sejam semelhantes às máscaras que são criadas por médicos especialistas.

1.1 Objetivos

Este trabalho tem por objetivo desenvolver uma metodologia baseada em redes neurais convolucionais para segmentações de lesões de pele, gerando imagens que possam ser aplicadas os métodos de classificação para um completo diagnóstico do Melanoma.

1.1.1 Objetivos Específicos

- Aprender, aplicar e desenvolver técnicas de aprendizado de máquina;
- Contribuir com uma ferramenta de seleção de área de lesão para diagnóstico de Melanoma;
- Avaliar a efetividade da solução proposta em bases públicas de imagens dermatoscópicas;

1.2 Trabalhos Relacionados

A maioria das técnicas de segmentação de imagens utiliza processos de aprendizado de máquina e recursos de extração de acordo com o tipo de imagem a ser segmentada. Existem alguns estudos na literatura que propõem técnicas importantes para diagnóstico de melanoma. Por exemplo, Green et al. (1994) propôs o uso de forma, cor e textura como características para a classificação automática. Lee et al. desenvolveram um sistema de diagnóstico de câncer que contém características morfológicas e uma etapa de classificação que implementa redes neurais artificiais. Chang et al. propuseram um método heurístico para extração de características e identificação de lesões. Fassihi utilizou operadores morfológicos usados e características de extração através de uma técnica baseada em uma Transformada Wavelet para segmentar as lesões de pele (FASSIHI et al., 2011).

As redes neurais profundas têm a capacidade de aprender abstrações complexas dos dados através de um processo de aprendizagem hierárquica muito similar ao que ocorre no cérebro humano, e além disso possui um bom desempenho de aprendizado. Redes Neurais Convolucionais (CNN) são adequadas para segmentação de dados de imagem e foram propostas por LeCun et al. em 1998 (LECUN et al., 1998).

Dependendo da forma como uma rede neural é estruturada, uma mudança relativamente discreta pode tornar mesmo as imagens gigantes mais fáceis de gerenciar. Em 2014, Urban et al. (2014) usou uma CNN comum para segmentar. A rede era constituída de uma série de camadas de convolução e uma função de ativação não linear entre cada camada e a camada de saída *softmax*. Em 2014, Pinheiro e Collobert (PINHEIRO; COLLOBERT, 2014) usaram uma CNN básica para prever cada *pixel* e melhoraram a previsão aperfeiçoando a CNN.

1.3 Estrutura do Trabalho

Este trabalho está organizado em cinco capítulos, de forma a apresentar o conteúdo mais claramente, conforme os parágrafos a seguir.

O Capítulo 2 apresenta a fundamentação teórica necessária para compreensão e embasamento deste estudo.

No Capítulo 3 é descrita a metodologia utilizada neste trabalho.

No Capítulo 4 são apresentados e discutidos os Resultados obtidos neste trabalho.

No Capítulo 5 é apresentada a Conclusão e os trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta a fundamentação teórica utilizada no desenvolvimento deste trabalho que é necessária para compreensão das técnicas utilizadas na metodologia proposta para a segmentação automática de lesões de pele. Assim, no decorrer do capítulo é discutida a base para o desenvolvimento deste estudo, partindo da compreensão de como é feita a captura das lesões e o funcionamento de redes neurais.

2.1 Dermatoscopia

A dermatoscopia é um método diagnóstico não invasivo para visualização das estruturas localizadas abaixo do estrato córneo, apresentando como principal indicação o estabelecimento do diagnóstico das lesões pigmentadas da pele, visando ao diagnóstico do melanoma cutâneo nas fases iniciais de evolução e infiltração (REZZE; NEVES, 2018).

A dermatoscopia, quando utilizada como ferramenta de diagnóstico de câncer de pele, tem um ganho significativo na acurácia final. Enquanto os especialistas que utilizam esse exame para realizar o diagnóstico têm uma acurácia de aproximadamente 90%, ao não utilizar, essa porcentagem cai cerca de 10% a 15% (MENZIES et al., 2001).

Figura 1 – Médico utilizando um dermatoscópio



Fonte: (CORRALO, 2018)

No exame, um feixe luminoso é emitido por uma lâmpada halógena que incide, em ângulo de 20 graus, na superfície cutânea, previamente preparada com aplicação de fluido (óleo, água, gel ou glicerina) na interface entre a epiderme e a lâmina de vidro do aparelho. Assim, elimina-se a reflexão da luz, permitindo sua penetração e a visualização

das características dermatoscópicas, resultantes principalmente da presença do pigmento melânico nas diferentes camadas da pele (epiderme e derme), hemoglobina dos vasos e fibrose dérmica (REZZE; NEVES, 2018).


A dermatoscopia tem como principal indicação estabelecer o diagnóstico precoce do melanoma e ajudar no diagnóstico diferencial das lesões melanocíticas da pele. Na figura 2b temos um exemplo de duas imagens geradas por um dermatoscópio, sendo uma benigna e a outra cancerosa. Através dos critérios definidos por esse método semiológico, é possível classificar as lesões melanocíticas em benignas, malignas ou suspeitas (quando os critérios não são suficientes para malignidade), reduzindo-se o número de biópsias desnecessárias (FRANGE; ARRUDA; DALDON, 2009).

Figura 2 – Exemplo de imagem dermatoscópica saudável e maligna

(a) Dermatoscopia de lesão maligna



(b) Dermatoscopia de lesão benigna



Fonte: (ARCHIVE, 2018)

2.2 Segmentação de imagens digitais

A segmentação de imagens é uma das etapas do Processamento de Imagem, e tem como principal objetivo distinguir classes dentro de uma imagem digital. Imagens digitais são representações discretas de objetos do mundo real ou imaginário, ou seja, que passaram pelo processo de digitalização. Neste processo, as imagens são representadas em um conjunto discreto de pontos distribuídos em forma matricial ou vetorial, sendo estes pontos chamados de *pixels* (AL, 2014).


A técnica de segmentação de imagem é usada para particionar uma imagem em diferentes partes significativas com características e propriedades semelhantes. O processo de segmentação tem como principal objetivo representar uma imagem em maneira significativa e facilmente analisável. A segmentação de imagens consiste no primeiro passo necessário na análise de imagens, sendo o mais importante e desafiador no processamento de imagens.

Existem bastantes aplicações no âmbito computacional que utilizam este processo, dentre eles podemos citar: Recuperação de imagens baseada em conteúdo, Imagens médicas, Detecção de objetos, sistemas automáticos de controle de tráfego e vídeo vigilância, etc. A segmentação da imagem pode ser classificada em dois tipos: segmentação local, que se preocupa com partes específicas da imagem e segmentação global, que tem como característica segmentar toda a imagem (CHIPANA, 2012).

2.3 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNAs) são abordagens que fazem parte do escopo da definição de Aprendizado de Máquina. Estas técnicas envolvem mecanismos adaptativos que permitem que computadores aprendam com base na experiência e esta capacidade de aprendizado faz com que o desempenho de sistemas inteligentes melhore com o tempo (NEGNEVITSKY, 2005).

Figura 3 – Representação de um neurônio humano



Fonte: (BARRETO, 2002)

Com base neste contexto, uma RNA pode ser definida como um modelo de raciocínio matemático baseado no cérebro humano. O cérebro consiste em um conjunto de células nervosas interconectadas, que são a unidade de processamento de informação, chamadas neurônios. O cérebro humano incorpora quase 10 bilhões de neurônios e 60 trilhões de conexões, as quais chamamos de sinapses. Ao utilizar múltiplos neurônios em paralelo, o cérebro pode executar suas funções muito mais rápido do que os computadores mais rápidos que existem atualmente. Embora cada neurônio tenha uma estrutura muito simples (ver Figura 3), um conjunto grande de tais elementos constitui um tremendo poder de processamento (NEGNEVITSKY, 2005).


O neurônio tem um corpo celular chamado soma, além de diversas ramificações. As ramificações conhecidas como dendritos, conduzem sinais das extremidades para o

corpo celular. Existe também uma ramificação, chamada axônio, que transmite um sinal do corpo celular para suas extremidades. As extremidades do axônio são conectadas com dendritos de outros neurônios pelas sinapses. As sinapses têm um papel fundamental na memorização da informação e são principalmente as do córtex cerebral que armazenam estas memórias, porém algumas vezes as partes mais profundas do cérebro que armazenam esta informação (BARRETO, 2002).

As RNAs são capazes de "aprender", isto é, usam a experiência para melhorar seu desempenho. Quando exposta a uma quantidade suficiente de amostras, as RNAs podem generalizar para os outros casos que ainda não foi apresentado. Existem diversas aplicações que utilizam RNAs atualmente, podemos citar: reconhecimento de caracteres manuscritos, identificação de fala humana e além disso, as RNAs podem observar padrões que especialistas humanos não conseguem reconhecer (NEGNEVITSKY, 2005).

Assim como o cérebro humano, as RNAs são compostas por neurônios que estão altamente interconectados. Os neurônios são conectados por pesos ponderados, que passam sinais de um para o outro. Cada neurônio recebe um número de sinais como entrada através de suas conexões, porém se produz apenas um único sinal de saída. O sinal de saída é transmitido através do neurônio conexão de saída, que correspondente ao axônio biológico. A conexão de saída, entretanto, se divide em vários ramos que transmitem o mesmo sinal. A saída de cada neurônio termina na entrada de um próximo (NEGNEVITSKY, 2005).

Figura 4 – Arquitetura básica de uma Rede Neural Artificial



Fonte: Adaptado de (NEGNEVITSKY, 2005)

Os neurônios são conectados por links, e cada link tem um peso numérico. Os pesos funcionam como meios básicos de memória de longo prazo em RNAs. Eles expressam a

intensidade, ou em outras palavras, a importância de cada entrada de neurônio. A rede neural, aprende então, baseado em múltiplos ajustes destes pesos. Cada neurônio é uma unidade elementar de processamento de informações e possui métodos de calcular seu nível de ativação, dadas as entradas e pesos numéricos. Um modelo considerado padrão de arquitetura de RNA é apresentado na Figura 4. Para construir uma rede neural artificial, devemos decidir primeiro a quantidade de neurônios iniciais e como os neurônios devem ser conectados para formar uma rede. Com isso, temos a arquitetura da rede. Após essa definição é definido qual algoritmo de aprendizado usar (NEGNEVITSKY, 2005).

O neurônio calcula a soma ponderada dos sinais de entrada e compara o resultado com um valor limiar, Θ . Se a entrada da rede for menor que o limiar, a saída de neurônio é -1. Mas se a entrada da rede for maior ou igual ao limiar, o neurônio se torna ativado e sua saída atinge um valor +1. Esta função de ativação pode ser representada na fórmula abaixo: onde X é a entrada ponderada da rede para o neurônio, x_i é o valor da entrada i , w_i é o peso da entrada i , n é o número de entradas de neurônios e Y é o valor saída do neurônio.

$$X = \sum_{i=1}^n x_i w_i$$

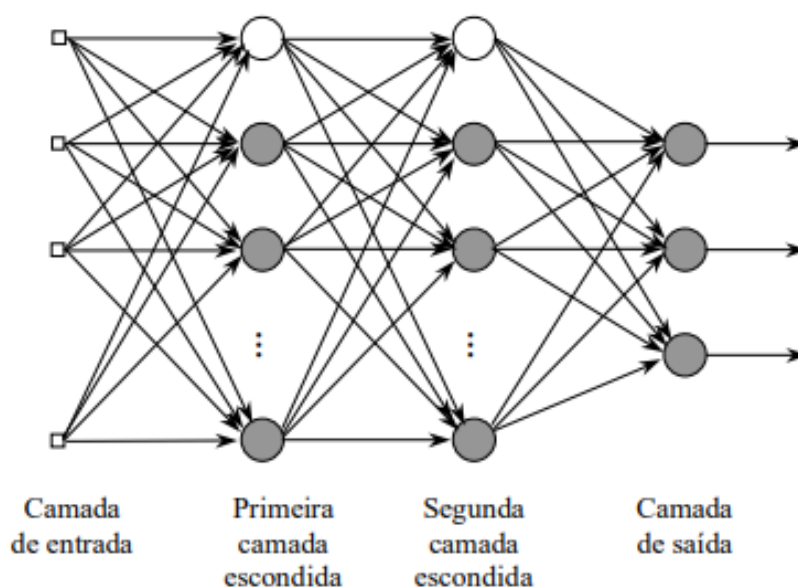
$$Y = \begin{cases} +1 & \text{se } X \geq \Theta \\ -1 & \text{se } X < \Theta \end{cases}$$

Este tipo de função de ativação é chamado de função de sinal. Existem outras funções de ativações: degrau, *sigmoid*, linear etc. Porém nem todas são aplicáveis a maioria dos problemas (NEGNEVITSKY, 2005).

Para resolver problemas que não podem ser resolvidos apenas com padrões linearmente separáveis, são utilizadas redes neurais com múltiplas camadas, o tipo de rede mais comum para resolução de problemas mais complexos são as perceptron de múltiplas camadas (MLP).

Tipicamente, esta arquitetura consiste de um conjunto de unidades sensoriais que formam uma camada de entrada, uma ou mais camadas intermediárias (ou escondidas) de unidades computacionais e uma camada de saída. Os sinais de entrada são propagados camada a camada pela rede em uma direção positiva, ou seja, da entrada para a saída. Esta arquitetura representa uma generalização do perceptron apresentado anteriormente.

Figura 5 – Arquitetura MLP com duas camadas intermediárias.



Fonte: (SILVA, 1998)

As redes do tipo MLP, com arquitetura representada na Figura 5, tem sido utilizada com sucesso para a solução de vários problemas envolvendo altos graus de não-linearidade. Seu treinamento é do tipo supervisionado e utiliza um algoritmo muito popular chamado retro-propagação do erro (*error backpropagation*). Este algoritmo é baseado numa regra de aprendizagem que “corrige” o erro durante o treinamento (SILVA, 1998).

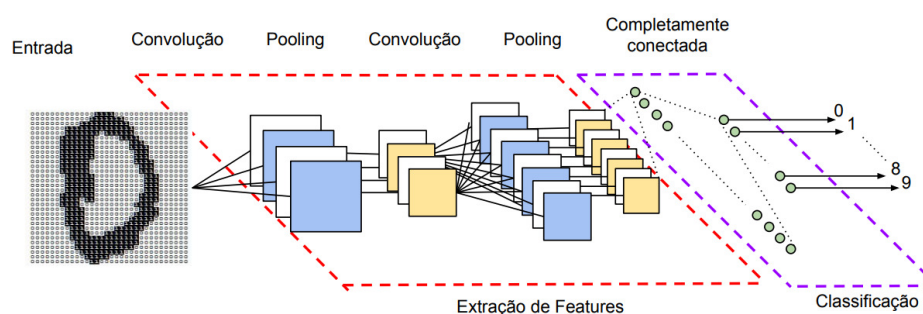
Basicamente, o processo de retro-propagação do erro é constituído de duas fases: uma fase de propagação do sinal funcional (*feedforward*) e uma de retro-propagação do erro. Na fase positiva, os vetores de dados são aplicados às unidades de entrada, e seu efeito se propaga pela rede, camada a camada. Finalmente, um conjunto de saídas é produzido como resposta da rede. Durante a fase positiva, os pesos das conexões são mantidos fixos. Na retro-propagação do erro, por outro lado, os pesos são ajustados de acordo com uma regra de correção do erro. Especificamente, a resposta da rede em um instante de tempo é subtraída da saída desejada para produzir um sinal de erro. Este sinal de erro é propagado da saída para a entrada, camada a camada, originando o nome “retro-propagação do erro”. Os pesos são ajustados de forma que a distância entre a resposta da rede e a resposta desejada seja reduzida (SILVA, 1998).

2.3.1 Redes Neurais Convolucionais

Uma Rede Neural Convolucional (CNN) é uma variação das redes perceptron de múltiplas camadas, tendo como inspiração o processo biológico de processamentos de dados

visuais. Assim como vários métodos aplicados no âmbito de processamento de imagens e visão computacional, uma CNN é capaz de aplicar filtros em dados visuais, mantendo a relação de vizinhança entre os *pixels* da imagem durante todo o processamento da rede. Essa arquitetura é muito utilizada atualmente, principalmente nas aplicações de classificação, detecção e reconhecimento em imagens e também em vídeos (VARGAS A. C. G.; PAES, 2016).

Figura 6 – Uma rede neural convolucional e suas diferentes camadas



Fonte: (VARGAS A. C. G.; PAES, 2016)

Uma rede neural convolucional consiste em várias partes com diversas funções. Geralmente, no passo inicial é comum aplicar sobre o dado de entrada camadas de convolução. Uma camada de convolução é composta por vários neurônios, no qual cada um é responsável por aplicar um filtro em uma parte específica da imagem. A combinação das entradas de um neurônio, aliado ao cálculo dos respectivos pesos de cada uma de suas conexões nos dá uma saída para a próxima camada, como podemos ver na Figura 6. Os pesos atribuídos as conexões de um neurônio podem ser interpretados como uma matriz que representa o filtro de uma convolução de imagens no domínio espacial, denominado *kernel* ou máscara (VARGAS A. C. G.; PAES, 2016).

Enquanto na arquitetura de perceptrons clássica os neurônios são conectados a todos os outros neurônios da camada anterior (completamente conectada), nas CNNs apenas um conjunto específico de entradas é conectado a cada neurônio. Com a mudança de arquitetura, as CNNs passam a realizar análise de campos receptivos locais (*local receptive fields*). Os neurônios da mesma camada são agrupados em mapas. Um mapa é gerado pelo agrupamento das saídas de neurônios que fazem parte de um conjunto que cobrem parte da imagem que tenha sido processado com o mesmo filtro (VARGAS A. C. G.; PAES, 2016).

Para que um conjunto de neurônios de um determinado mapa aplique o mesmo filtro em diferentes posições da imagem, é feito um compartilhamento dos pesos durante o

processo de treinamento. Tal compartilhamento reduz o número de parâmetros a serem aprendidos e o tempo de treinamento da rede. O filtro a ser aplicado na imagem é representado visualmente por apenas um neurônio. O tamanho do filtro define o tamanho da vizinhança que cada neurônio da camada irá processar. O valor do passo (*stride*) representa quantos *pixels* serão pulados entre cada janela, dizendo-nos qual será o tamanho da camada seguinte na mesma unidade (VARGAS A. C. G.; PAES, 2016).

Quando se utiliza camadas de convolução nas CNNs, não é necessário definir qual filtro utilizar, logo, precisa-se apenas definir a arquitetura dos filtros: tamanho, quantidade e *stride*. O processo de aprendizado da rede altera os pesos ao longo do treinamento, executando várias iterações até encontrar os valores mais apropriados para a resolução do problema. Uma das formas de se avaliar o aprendizado é verificar as ativações dos filtros obtidos no final do treinamento. Em redes voltadas para a detecção de objetos, as camadas iniciais geralmente aprendem filtros de arestas, bordas e cores. Analisando níveis mais profundos, detectam-se pedaços de interesse e detalhes cada vez mais complexos (VARGAS A. C. G.; PAES, 2016).

Geralmente logo após a convolução aplica-se uma função de ativação. Estas funções em cada neurônio são responsáveis por realizar uma transformação nos dados recebidos. É comum utilizar funções com algum grau de não-linearidade, e isso permite que as aplicações sucessivas dessas distorções tornem as classes de saída linearmente separáveis. Um outro conceito muito importante que geralmente é aplicado após as convoluções são as camadas agrupamento (*pooling*). A função dessas camadas é reduzir a dimensionalidade dos dados na rede. Essa redução é importante por questão de agilidade no treinamento, mas principalmente para criar invariância espacial. A camada de *pooling* funciona agrupando um conjunto de dados, por exemplo: a entrada é dividida em janelas 3x3 e de cada uma é selecionado um valor para os representar. Essa escolha pode ser feita por diversas funções, porém, a mais utilizada é a função de máximo. É importante mencionar que a camada de *pooling* não reduz a profundidade da entrada, ela apenas reduz a altura e a largura de um mapa (VARGAS A. C. G.; PAES, 2016).

No próximo capítulo, será explanada a metodologia proposta neste trabalho, além da explicação da aplicação dos conceitos que vimos a pouco.

3 METODOLOGIA

Neste capítulo, é apresentado o fluxo de etapas adotado para efetuar a segmentação semântica de imagens dermatoscópicas. Primeiramente, são apresentadas as bases de imagens dermatoscópicas utilizadas neste trabalho. Em seguida, as ferramentas utilizadas para o desenvolvimento do método proposto são explanadas. Logo após, cada etapa que constitui a metodologia é detalhada. Por fim, são apresentadas as métricas utilizadas para a avaliação do método. A Figura 7 apresenta a sequência de etapas envolvidas na metodologia proposta neste trabalho.




Figura 7 – Etapas da Metodologia Proposta.

3.1 Materiais

A linguagem de programação utilizada no desenvolvimento deste trabalho foi *Python* (versão 3.5.6). Além disso, biblioteca *Keras* foi utilizada na modelagem de toda a estrutura da Rede Neural utilizada no trabalho.

Para realização dos testes e implementação da rede, foi utilizado a ferramenta *Google Colaboratory* (GOOGLE, 2017), que é um serviço gratuito da Google para pesquisadores e desenvolvedoras do ramo de Inteligência Artificial. Este serviço possui configurações muito robustas que auxiliaram em testes mais rápidos. A ferramenta conta com processador Intel(R) Xeon(R) CPU @ 2.30GHz e GPU uma Tesla K80 GPU.

3.2 Aquisição de dados

Para este trabalho, foram utilizadas duas bases de dados distintas a fim de garantir uma maior confiabilidade dos resultados. A primeira é uma base pública chamada PH2 e a segunda é composta por um conjunto de imagens retiradas de um repositório, também público, de imagens dermatoscópicas, o ISIC-Archive.

A base de imagens dermatoscópicas PH2 foi criada em uma pesquisa conjunta entre a Universidade do Porto, Técnico Lisboa e serviço de dermatologia do Hospital Pedro Hispano em Matosinhos, Portugal. A base possui um total de 200 imagens, sendo elas divididas entre 80 imagens de nevos comuns, 80 imagens de nevos atípicos e 40 imagens com lesões do tipo melanoma. As imagens dermatoscópicas foram obtidas sob as mesmas condições através do sistema *Tuebinger Mole Analyzer*, que é um sistema médico de dermatoscopia, usando uma ampliação de 20x. São imagens coloridas RGB de 8 bits com uma resolução de 768 x 560 *pixels* (MENDONCA et al., 2013).

Para cada imagem no banco de dados, estão disponíveis a segmentação manual de um especialista (ver Figura 8), o diagnóstico da lesão e a identificação de alguns critérios dermatoscópicos. Dentre esses critérios, podemos citar a avaliação da assimetria da lesão, identificação das variadas cores e algumas estruturas diferentes, como pontos, glóbulos, estrias, áreas de regressão e véu azul-esbranquiçado (MENDONCA et al., 2013).

Fonte: (MENDONCA et al., 2013)




Figura 8 – Imagens extraídas do dermatoscópio em cima e na parte de baixo temos a Segmentação manual realizada pelo especialista.

A segunda base de dados é fruto do *International Skin Imaging Collaboration: Melanoma Project* (ISIC), que é uma parceria da academia e da indústria criada para facilitar a aplicação de imagens digitais de pele para ajudar a reduzir a mortalidade por melanoma. Atualmente, a falta de padrões para imagens dermatológicas prejudica a qualidade e a utilidade das imagens da lesão da pele. O projeto ISIC está desenvolvendo padrões propostos para abordar as tecnologias, técnicas e terminologia usadas na geração de imagens da pele, com atenção especial às questões de privacidade e interoperabilidade (ou seja, a capacidade de compartilhar imagens entre plataformas tecnológicas e clínicas). Além disso, o ISIC desenvolveu e está expandindo um repositório de acesso público de fonte aberta (*ISIC Archive*) de imagens de pele para testar e validar os padrões propostos. Este arquivo serve como um recurso público de imagens para o ensino e para o desenvolvimento e teste de sistemas de diagnóstico automatizados (PROJECT, 2018).

O repositório possui atualmente cerca de 23 mil imagens, considerando as lesões e a segmentação gerada pelo especialista. Além disso, essas imagens podem ser filtradas de acordo com: idade aproximada, tamanho da lesão, tipo de diagnóstico, sexo e histórico familiar, além de classificar se a lesão é maligna ou benigna. Para este trabalho, foi utilizado um *script* proposto por (AVINERI, 2016) para realizar o download de imagens do repositório de acordo com alguns filtros. Foi utilizada uma base de 500 imagens, divididas igualmente entre lesões benignas e malignas.

Apesar de ter um número expressivo de imagens, mais de 82% das imagens do repositório ISIC são constituídas de lesões benignas, cuja maioria representa nevos melanócitos (pintas comuns). A segmentação dessas pintas é fácil de se realizar por elas geralmente serem simétricas, com bordas bem definidas e com cores uniformes. Além disso, existem imagens que não foram consideradas para a base retirada pois utilizam um marcador de escala colorido que seria significativo na segmentação semântica.

As imagens são apresentadas de forma semelhante à base PH2, sendo cada lesão composta por uma imagem dermatoscópica e a segmentação realizada por um especialista. Além da maior diversidade do repositório ISIC, outra grande diferença entre as bases é o tamanho da imagem, que no repositório é bastante variado. Com o objetivo de diminuir o custo computacional do processamento da Rede Convolutiva, as imagens de ambas as bases foram redimensionadas para a resolução 256×256 pixels.

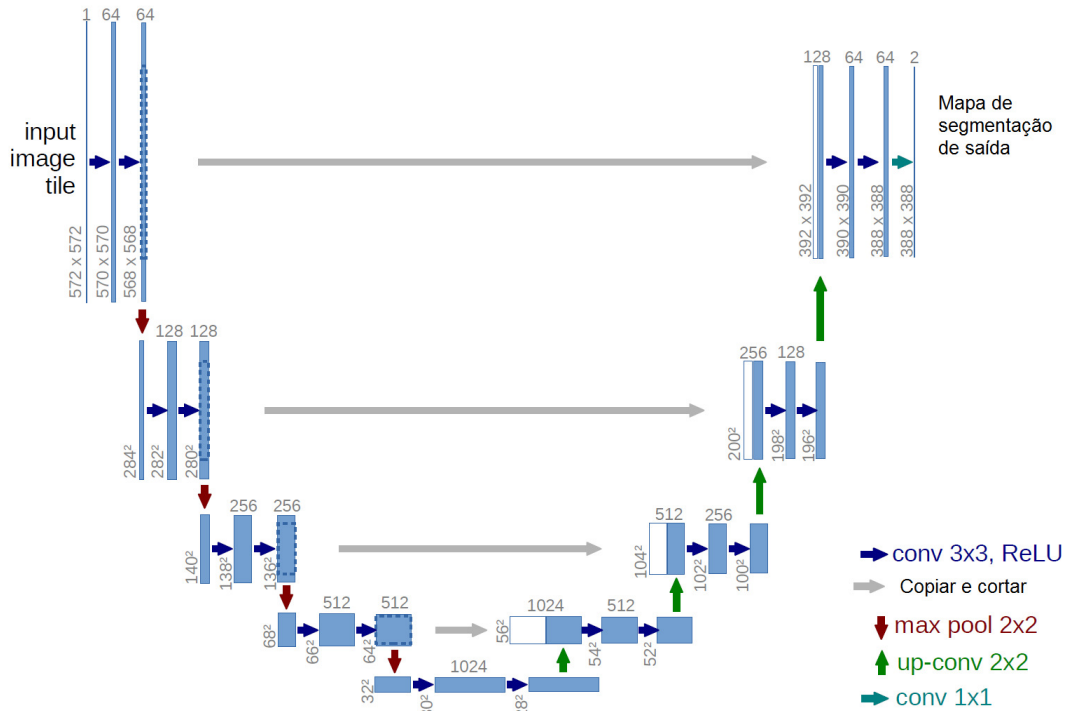
3.3 Segmentação semântica utilizando U-NET

Nesta seção é explicado quais ferramentas e técnicas foram utilizadas para implementação da Rede Convolutiva utilizada neste trabalho.

As redes neurais convolucionais são usadas na maioria das vezes para resolver tarefas de classificação, nas quais a saída para uma imagem é um rótulo de uma mesma classe. Porém, existem tarefas em que cada *pixel* da imagem deve conter um rótulo associado. Tarefas de processamento biomédico de imagens possuem essa característica e esta subseção apresenta a U-Net, uma arquitetura de rede neural que foi desenvolvida especialmente para segmentação de imagens médicas.

A U-Net é uma rede completamente convolutiva, na qual se pode trabalhar com poucas imagens e garantir precisão no resultado. A rede consiste em camadas de contração e camadas de expansão, o que dá a arquitetura um formato de U. As camadas de contração compõem uma rede convolutiva típica que consiste na aplicação repetida de convoluções, cada uma seguida por uma unidade linear retificada (ReLU) e uma operação de *Max Pooling*. As camadas expansivas combinam as características e as informações espaciais através de uma sequência de convoluções e concatenações (RONNEBERGER; BROX, 2015).

Figura 9 – Arquitetura da rede U-net.



Adaptado de (RONNEBERGER; BROX, 2015)

A rede não possui nenhuma camada totalmente conectada e utiliza apenas a parte válida de cada convolução, ou seja, o mapa de segmentação contém apenas os *pixels*, o que faz com que essa estratégia permita uma boa segmentação de imagens grandes. Para realizar a segmentação da borda da imagem, o contexto ausente é preenchido utilizando uma técnica de espelhamento da imagem de entrada (RONNEBERGER; BROX, 2015).

A arquitetura da U-Net utilizada neste trabalho é representada na Figura 9 e é baseada na arquitetura padrão da rede proposta por (RONNEBERGER; BROX, 2015), sendo a quantidade de filtros de cada camada a única diferença. Nesta ilustração, cada retângulo em azul corresponde a uma camada e o número de filtros daquela camada é indicado na parte superior do retângulo. O tamanho da imagem é fornecido no canto inferior esquerdo dos retângulos. Os retângulos brancos representam filtros copiados. As setas denotam as operações realizadas pela rede.

Como entrada, a rede recebe 3 canais de uma imagem dermatoscópica pré-processada na etapa anterior e em seguida são aplicadas duas convoluções seguidas com *kernel* 3x3. Todas as convoluções da rede são seguidas de uma ReLU, que pode ser descrita pela Equação 3.1.

$$g(x) = \max(x, 0) \tag{3.1}$$

As camadas de contração são seguidas por uma operação de *Max Pooling* com tamanho de *kernel* 2x2, que reduz a resolução dos mapas de características recebidos pela metade e dobra a quantidade de filtros. Já as camadas expansivas são seguidas de operações *upsampling*, realizadas por meio de de-convoluções de *kernel* 2x2. Esta operação reduz o número de filtros pela metade e expande a resolução dos mapas de característica com a adição de 0 às bordas para que a resolução seja exatamente o dobro da entrada.

Toda camada que é seguida pela operação de *upsampling* é concatenada com a cópia da camada exatamente a sua esquerda (ver Figura 9). E para finalizar, uma última camada de convolução com *kernel* 1x1 é usada para mapear os mapas de características em cada *pixel* da imagem de saída, com a função de ativação sigmoide, representada na Equação 3.2. Esta operação resulta em uma máscara binária para segmentação.

$$h_{\theta}(x) = \frac{1}{1 + e^{-\theta^T x}} \quad (3.2)$$

3.3.1 Avaliação

Para avaliar os resultados propostos pelo método utilizado neste trabalho foram usadas métricas de avaliação que são comuns na literatura de segmentação de imagens. As métricas são baseadas na classificação dos *pixels* segmentados em relação a segmentação da máscara gerada pelo especialista. Neste contexto, os *pixels* podem ser classificados em: Verdadeiro Positivo (VP), Verdadeiro Negativo (VN), Falso Positivo (FP) e Falso Negativo (FN).

Considera-se VP um *pixel* que faz parte da região de interesse(lesão) e que foi corretamente segmentado pela técnica proposta de acordo com a marcação do especialista. Já os VN são aqueles *pixels* que não foram segmentados pela técnica avaliada, e de fato não fazem parte da lesão. De forma análoga, FP são todos os *pixels* que foram segmentados pelo método proposto que não pertencem a região desejada, e FN são os *pixels* que pertencem a região de interesse, mas que não foram segmentados pela técnica utilizada.

Ao total foram utilizadas quatro métricas para comparação dos resultados. Duas delas são mais simples: Sensibilidade e Precisão. Podemos considerar a Sensibilidade como a proporção de VP, ou seja, a capacidade do sistema em prever corretamente a condição para casos que realmente a têm. Um valor de Sensibilidade alto indica que a técnica de segmentação consegue retornar boa parte da região de interesse, o que significa que ela retorna poucos FN. A sensibilidade pode ser calculada de acordo com a Equação 3.3. Uma outra métrica simples é a precisão. Um índice de Precisão alto indica que o método de segmentação retornou uma quantidade maior de *pixels* que pertencem a região de interesse,

quando comparada com o número de FP (PESSOA, 2017). A Precisão pode ser calculada de acordo com a equação 3.4.

$$\text{Sensibilidade} = \frac{VP}{VP + FN} \quad (3.3)$$

$$\text{Precisão} = \frac{VP}{VP + FP} \quad (3.4)$$

Uma das métricas mais utilizadas no contexto de segmentação de imagens é o Coeficiente de Similaridade de Dice (CSD) (DICE, 1945). Este coeficiente pode ser calculado de acordo com a equação 3.5.

$$\text{CSD} = \frac{2VP}{2VP + FP + FN} \quad (3.5)$$

Além disso, o CSD também pode ser representado em relação a Sensibilidade e Precisão, como apresentado na Equação 3.6.

$$\text{CSD} = \frac{\text{Sensibilidade} \cdot \text{Precisão}}{\text{Sensibilidade} + \text{Precisão}} \quad (3.6)$$

Uma outra métrica utilizada para avaliação dos resultados foi a *Intersection over Union* (IoU), ou Índice de Jaccard, proposto por (JACCARD, 1901). A diferença desse índice para o CSD é o fato de que o fator VP é multiplicado por 2 no CSD. A ausência desse produto no IoU faz com que erros sejam mais penalizados nesse índice que no CSD (PESSOA, 2017). O IoU pode ser calculado de acordo com a Equação 3.7.

$$\text{IoU} = \frac{VP}{VP + FP + FN} \quad (3.7)$$

No capítulo seguinte, são mostrados os resultados dessa metodologia aplicada as duas bases de dados antes mencionadas.

4 RESULTADOS

A avaliação do método proposto para segmentação foi feita através das métricas de Sensibilidade, Precisão, IoU e coeficiente de Dice. Para a base PH2, o método de separação foi uma divisão aleatória na proporção de 30% das imagens para teste e 70% para treino. Para a base autoral retirada do repositório ISIC, foi feita uma separação para que houvesse uma quantidade igual na proporção de lesões benignas e malignas, sendo assim, para teste foram separadas 30% das imagens, sendo que 15% contendo lesões benignas e o restante de lesões cancerosas. Para treino utilizou-se a mesma lógica, sendo 35% contendo lesões benignas e 35% representando lesões malignas .

Para a realização dos testes, o método de otimização para treinamento da rede foi Adam (KINGMA D.; BA, 2014) com taxa de aprendizado de 0.001. A função de perda utilizada foi a Entropia Cruzada (MANNOR; PELEG; RUBINSTEIN, 2005). Dessa forma, foram realizados três execuções em cada uma das bases.

As Tabelas 1 e 2 apresentam os resultados obtidos na etapa de segmentação das imagens dermatoscópicas nas bases de dados PH2 e autoral, respectivamente. São apresentados os resultados individuais para cada base, assim como a média e o desvio padrão dos valores obtidos em cada uma das quatro métricas. Os valores dos índices de Precisão e Sensibilidade se mantiveram consistentemente altos durante todas as instâncias de teste, o que indica que uma grande parte das regiões segmentadas pelo método vão pertencer a região da lesão, além de garantir que boa parte da região da lesão vai ser segmentada pela rede.

Instância	Sensibilidade	Precisão	<i>Dice</i>	IoU
Teste 1	97,72	97,83	97,58	94,2
Teste 2	98,28	98,78	97,61	95,37
Teste 3	98,08	98,06	97,81	95,65
Média	98,02	98,22	97,66	95,07
Desvio Padrão	0,23	0,40	0,10	0,62

Tabela 1 – Resultados da segmentação na base PH2


Instância	Sensibilidade	Precisão	<i>Dice</i>	IoU
Teste 1	96,69	97,56	97,2	94,1
Teste 2	97,99	97,99	97,82	95,73
Teste 3	97,96	97,96	97,73	95,56
Média	97,54	97,83	97,58	95,13
Desvio Padrão	0,74	0,24	0,33	0,89

Tabela 2 – Resultados da segmentação na base Autoral

Com os valores de Precisão e Sensibilidade, consideravelmente elevados, os valores do CSD e IoU também foram bastante satisfatórios. Isso indica que o método foi bastante satisfatório para a segmentação das imagens. Essa ideia é reforçada ainda mais pelo fato do desvio padrão ser consistentemente baixo para todas as métricas, o que mostra que provavelmente não ocorreu sobre-ajuste, ou seja, a rede não se ajustou para as instâncias de treino.


As Figuras 10 e 11 ilustram as curvas de aprendizagem das redes responsáveis pela segmentação das imagens dermatoscópicas nas bases PH2 e aortal, respectivamente. Esses gráficos representam o desempenho da rede aplicada na divisão de validação, medido pelo CSD no primeiro gráfico e pelo IoU no segundo, a cada época durante seu treinamento. Verifica-se que a rede conseguiu alcançar um valor de CSD relativamente alto em menos de 80 épocas, e após uma oscilação seu desempenho ainda melhorava lentamente durante o restante das épocas. A segunda alcançou um índice de IoU relativamente alto em aproximadamente 80 épocas apesar da oscilação até este ponto e após isso manteve um leve crescimento no aprendizado até o final do treino.

Figura 10 – Curva de aprendizagem para segmentação na base PH2



Fonte: Acervo do autor

Figura 11 – Curva de aprendizagem para segmentação na base aortal



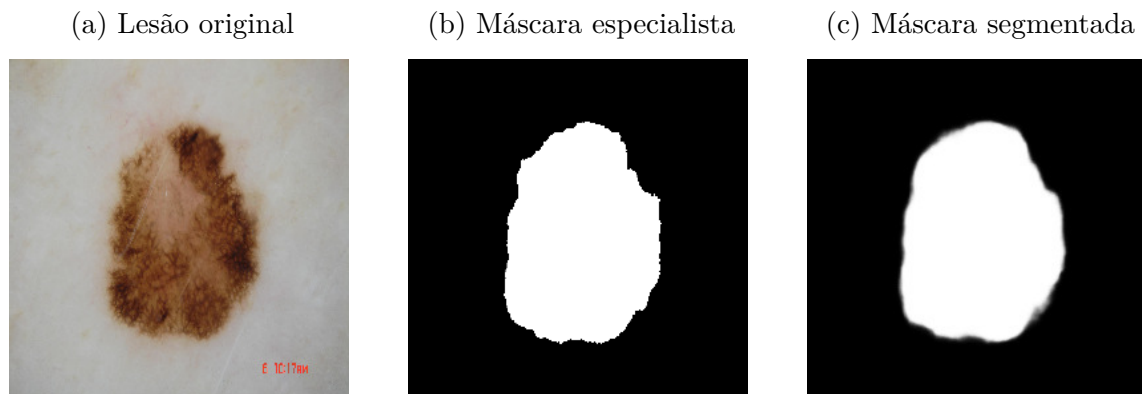
Fonte: Acervo do autor

4.1 Estudos de Casos

Nesta seção são mostrados três casos de segmentação da U-Net em imagens de lesões classificadas como Melanoma retiradas da base de dados autoral. As imagens são divididas entre: uma lesão com bordas uniformes e algumas variações de cor considerada de fácil segmentação, uma lesão com bordas irregulares e pouca variação de cor considerada de média complexidade e por fim, uma lesão sem bordas definidas, com bastantes variações de cores e com variadas texturas que se considerou de difícil segmentação.

A Figura 12 apresenta um exemplo da execução da segmentação da U-Net. A máscara gerada envolveu uma parte considerável da região da lesão, com desvios quase imperceptíveis nas bordas. Apesar da imagem de entrada representar um Melanoma, a maioria das lesões Benignas apresentam padrões semelhantes a esta imagem, com cores bem definidas e bordas consideradas regulares sem alterações significativas na textura.

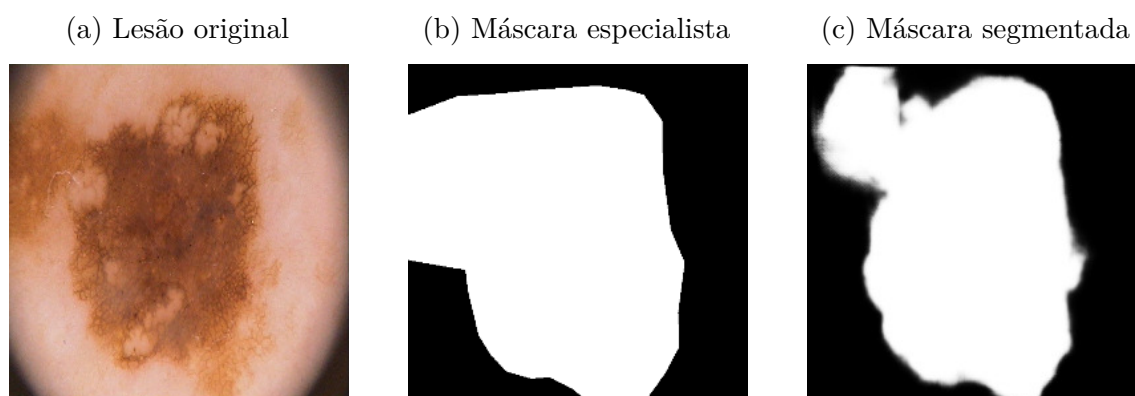
Figura 12 – Exemplo de saída de uma imagem cancerosa de fácil segmentação da base autoral.



Fonte: Acervo do autor

Como já foi explicado, algumas lesões malignas tendem a ser assimétricas e possuir bordas bastante irregulares. A segmentação de uma imagem dermatoscópica com essas características é apresentada na Figura 13. Nesta imagem, a U-Net conseguiu segmentar bem a região central da lesão de forma que os contornos foram bem semelhantes a máscara desenhada pelo especialista em boa parte da área. Porém a lesão se estende no canto superior esquerdo e a imagem gerada acaba com bastantes falsos negativos na parte esquerda da extensão da lesão e algumas ocorrências de Falsos Positivos na parte superior, que possivelmente foram geradas pela borda do dermatoscópio na imagem.

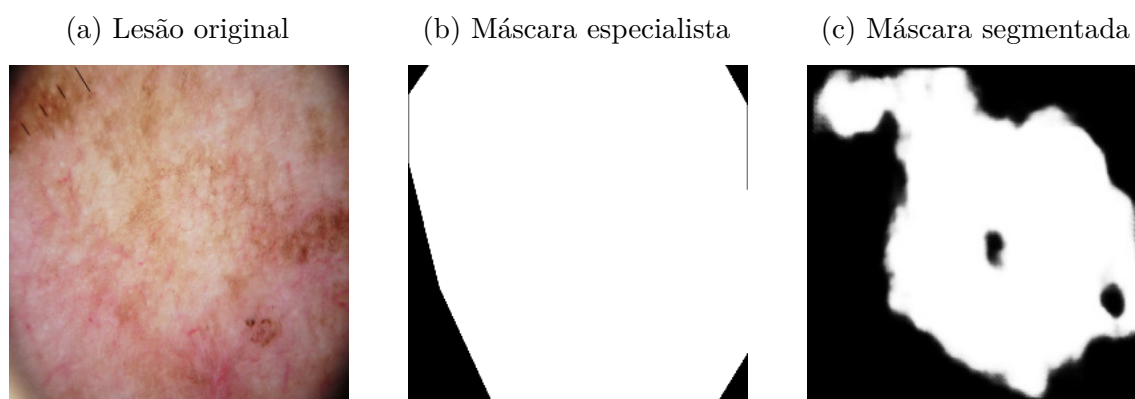
Figura 13 – Exemplo de saída de uma imagem cancerosa de complexidade média da base autoral.



Fonte: Acervo do autor

Já a Figura 14 mostra uma segmentação errônea por parte deste metodologia. Para esta lesão, toda a região segmentada pelo especialista é englobada pela máscara gerada, não havendo Falsos Positivos mas com a maioria dos *pixels* classificados como Falso Negativos. Todavia, a lesão é um pouco descaracterizada da maioria das imagens classificadas como Melanoma, sendo a cor da lesão muito semelhante a cor da pele do paciente. Desta forma, fazer a distinção entre pele e lesão nesta imagem é uma tarefa muito difícil até mesmo para um especialista, que acabou desenhando uma máscara que englobasse praticamente toda a imagem, enquanto o método proposto levou em consideração a região mais esbranquiçada da imagem como lesão.

Figura 14 – Exemplo de saída de uma imagem cancerosa de difícil segmentação da base autoral.



Fonte: Acervo do autor

No capítulo seguinte, é discutido o que foi concluído neste trabalho, além de sugestões para trabalhos futuros.

5 CONCLUSÃO

O índice de ocorrências de câncer de pele tem aumentado bastante nos últimos anos em diversos países. A dermatoscopia é uma das maiores ferramentas para diagnóstico precoce deste tipo de câncer e quanto mais cedo a descoberta, maiores as chances de cura.

Este trabalho apresentou uma proposta de método para a segmentação automática de lesões de pele em imagens dermatoscópicas com foco na utilização de redes neurais convolucionais, especificamente a arquitetura U-Net, que tem como foco a segmentação de imagens médicas.

O método proposto obteve resultados excelentes, de forma que as duas principais métricas para avaliar segmentação de imagens mantiveram-se elevadas durante todos os testes em ambas as bases de dados que utilizam imagens públicas. As médias para Precisão, Sensibilidade e Coeficiente de Dice foram um pouco maiores que 97%. Já para o índice de Jacard a média foi de aproximadamente 95%.

Tais resultados são importantes para ferramentas que tenham como objetivo o diagnóstico automático do melanoma, visto que uma boa segmentação é de total importância para os passos posteriores do diagnóstico.

Como trabalhos futuros, é sugerido que sejam utilizadas mais técnicas de pré-processamento que possam melhorar o conteúdo antes do treino, como por exemplo: retirada de pelos e representação da imagem em algum canal de cor que melhor diferencie a lesão da pele. Além disso, indica-se também a utilização de métodos de validação cruzada para realizar treinos mais consistentes. Outra indicação é a utilização de algum método para otimização dos parâmetros da rede, como quantidade de filtros em cada camada, tamanho do *batch*, etc.

Referências

- AL, D. K. et. Various image segmentation techniques: A review. *International Journal of Computer Science and Mobile Computing*, p. 809–814, 2014. Citado na página 15.
- ARCHIVE, I. <https://isic-archive.com/>. 2018. Citado na página 15.
- AVINERI, G. <https://github.com/GalAvineri/ISIC-Archive-Downloader>. 2016. Citado na página 24.
- BARRETO, J. M. Introdução as redes neurais artificiais. *V Escola Regional de Informática. Sociedade Brasileira de Computação, Regional Sul, Santa Maria, Florianópolis, Maringá*, p. 5–10, 2002. Citado 2 vezes nas páginas 16 e 17.
- CHIPANA, Y. I. F. E. A. Segmentação de imagens: abordagens para reconhecimento de placas de veículos. 2012. Citado na página 16.
- CORRALO, D. S. <https://www.webconsultas.com/pruebas-medicas/dermatoscopia-digital>. 2018. Citado na página 14.
- DICE, L. R. *Measures of the amount of ecologic association between species*. 1945. 297–302 p. Citado na página 27.
- FASSIHI, N.; SHANBEHZADEH, J.; SARRAFZADEH, A.; GHASEMI, E. Melanoma diagnosis by the use of wavelet analysis based on morphological operators. *Proceedings of the International Multiconference of Engineers and Computer Scientists.*, p. 16–18, 2011. Citado na página 12.
- FRANGE, V.; ARRUDA, L.; DALDON, P. Dermatoscopia: importância para a prática clínica. *Rev. Ciênc. Méd.*, p. 209–215, 2009. Citado na página 15.
- GOOGLE. *Google Colaboaoty*. 2017. Disponível em: <<https://colab.research.google.com>>. Citado na página 22.
- GREEN, A.; MARTIN, N.; PFITZNE, J.; O'ROURKE, M.; KNIGHT, N. Computer image analysis in the diagnosis of melanoma. *J Am Acad Dermatol*, v. 31, p. 958–964, 1994. Citado na página 12.
- INCA. *PELE MELANOMA*. 2018. Disponível em: <http://www2.inca.gov.br/wps/wcm/connect/tiposdecancer/site/home/pele_melanoma/definicao+>. Citado na página 11.
- JACCARD, P. *Étude comparative de la distribution florale dans une portion des alpes et des jura*. 1901. 547–579 p. Citado na página 27.
- KINGMA D.; BA, J. A. *A method for stochastic optimization*. 2014. Citado na página 28.
- LECUN, Y.; BOTTOU, L.; BENGIO, Y.; HAFFNER, P. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, v. 86, n. 11, p. 2278–2324, Nov 1998. ISSN 0018-9219. Citado na página 12.
- MANNOR, S.; PELEG, D.; RUBINSTEIN, R. *The cross entropy method for classification*. 2005. Citado na página 28.

- MENDONCA, T.; FERREIRA, P. M.; MARQUES, J. S.; MARÇAL, A. R. S.; ROZEIRA, J. Ph2 - a dermoscopic image database for research and benchmarking. *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, p. 5437–5440, 2013. Citado na página 23.
- MENZIES, S.; GUTENEV, A.; AVRAMIDIS, M.; BATRAC, A.; MCCARTHY, W. Short-term digital surface microscopic monitoring of atypical or changing melanocytic lesions. *Arch Dermatol*, p. 1583–9, 2001. Citado na página 14.
- NEGNEVITSKY, M. *Artificial intelligence: a guide to intelligent systems*. [S.l.: s.n.], 2005. Citado 3 vezes nas páginas 16, 17 e 18.
- PESSOA, A. C. P. *Diagnóstico Automático de Glaucoma em Retinografias baseado no CDR usando U-Net*. 2017. Citado na página 27.
- PINHEIRO, P. O.; COLLOBERT, R. Recurrent convolutional neural networks for scene labeling. In: *Proceedings of the 31st International Conference on International Conference on Machine Learning - Volume 32*. JMLR.org, 2014. (ICML'14), p. I–82–I–90. Disponível em: <<http://dl.acm.org/citation.cfm?id=3044805.3044816>>. Citado na página 12.
- PROJECT, I. <https://isdis.org/isic-project/>. 2018. Citado na página 23.
- REZZE, G.; NEVES, R. Dermatoscopia: o método de análise de padrões* dermoscopy: the pattern analysis. 12 2018. Citado 2 vezes nas páginas 14 e 15.
- RONNEBERGER, P. F. O.; BROX, T. U-net: Convolutional networks for biomedical image segmentation. 2015. Citado 2 vezes nas páginas 24 e 25.
- SILVA, L. N. de C. *ANÁLISE E SÍNTESE DE ESTRATÉGIAS DE APRENDIZADO PARA REDES NEURAIAS ARTIFICIAIS*. 1998. Citado na página 19.
- URBAN, G.; BENDSZUS, M.; HAMPRECHT, F. A.; KLEESIEK, J. Multi-modal brain tumor segmentation using deep convolutional neural networks. In: *MICCAI BraTS (Brain Tumor Segmentation) Challenge. Proceedings, winning contribution*. [S.l.: s.n.], 2014. p. 31–35. Citado na página 12.
- VARGAS A. C. G.; PAES, A. V. C. N. *Um Estudo sobre Redes Neurais Convolucionais e sua Aplicação em Detecção de Pedestres*. 2016. Citado 2 vezes nas páginas 20 e 21.