

# Uma revisão sistemática da literatura sobre a utilização de algoritmos de *Machine Learning* para classificação de casos de câncer de pele com base em imagens dermatoscópicas

Alexis Davidson Maciel de Barros<sup>1</sup>, Mônica Ximenes Carneiro da Cunha<sup>1</sup>

<sup>1</sup>Coordenação de Informática – Instituto Federal de Alagoas (IFAL)  
CEP 57.020-600 – Maceió – AL – Brasil

apenasalexis@gmail.com, mxcc@hotmail.com

**Abstract.** *The skin cancer is the most common type of cancer today. According to Instituto Nacional de Câncer – INCA, every year, about 180 thousand new cases are registered. Machine Learning techniques are being used more and more to help in the malignant tumors identify. The aim of this work is investigate and map which Machine Learning algorithms, as well as which Databases, are been used to classifier skin cancer cases based on dermatoscopic images. As methodology, literature systematic review – RSL, was used and analised 40 studies of following sources: Google Scholar, Science Direct, IEEE and Scielo. This studies were selected based in a “search String” and inclusion and exclusion criteria. It was observed that the most used algorithms are the Convolutional Neural Networks (CNN) and Support Vector Machines (SVM). The most used Databases are the ISIC and PH2 dataset.*

**Resumo.** *O câncer de pele é o tipo mais comum de câncer. Conforme o Instituto Nacional de Câncer – INCA, a cada ano, cerca de 180 mil novos casos são registrados. Técnicas de Machine Learning estão cada vez mais sendo utilizadas para ajudar na identificação de tumores malignos. O objetivo deste trabalho é investigar e mapear quais algoritmos de Machine Learning, bem como quais as bases de dados, estão sendo utilizados para classificar casos de câncer de pele com base em imagens dermatoscópicas. Como metodologia, utilizou-se uma Revisão Sistemática da Literatura – RLS, onde foram analisados 40 estudos das seguintes fontes: Google Scholar, Science Direct, IEEE e Scielo. Tais estudos foram selecionados com base em uma String de busca e critérios de inclusão e exclusão. Observou-se que os algoritmos mais utilizados são as Redes Neurais Convolucionais (CNN) e as Máquinas de Vetores de Suporte (SVM). Já as bases de dados mais utilizadas são a ISIC e a PH2 dataset.*

## 1. Introdução

De acordo com o Instituto Nacional de Câncer – INCA<sup>1</sup>, o câncer pode ser definido como uma doença que tem como característica o crescimento desordenado de células, que invadem tecidos e órgãos. Essas células se dividem de forma rápida e incontrolável, formando tumores que se espalham para outras regiões do corpo.

Existem diversos tipos de câncer, cada um relacionado a um tipo de célula do

---

1 Informação disponível em <https://www.inca.gov.br/tipos-de-cancer/cancer-de-pele-melanoma>

corpo como pele, mucosas, ossos e músculos. A velocidade de multiplicação das células e a capacidade de invadir outros tecidos e órgãos são algumas das características que diferenciam os tipos de câncer [INCA 2018].

O câncer de pele é o tipo mais comum de câncer. Ainda conforme o INCA, a cada ano, cerca de 180 mil novos casos são registrados. Essa doença é causada pelo crescimento anormal e descontrolado das células que compõem a pele. Seus diferentes tipos são determinados a partir das diversas camadas de células que forem afetadas [SBD 2019]. Segundo a Sociedade Brasileira de Dermatologia (SBD), os tipos mais comuns de câncer de pele são os carcinomas basocelulares e os espinocelulares. Já o mais raro, agressivo e letal é o melanoma.

O melanoma pode aparecer em qualquer parte do corpo na forma de manchas, pintas ou sinais e a identificação delas é feita por meio da regra do ABCDE. De acordo com essa regra, a lesão identificada na pele é classificada com base nas seguintes características: Assimetria, bordas irregulares, cor variável, diâmetro e evolução [INCA 2018]. Essas características são observadas pelo profissional médico por meio de um dermatoscópio, aparelho que funciona como uma lente de aumento, que deixa em evidência a lesão na pele permitindo uma análise mais aprofundada e um diagnóstico confiável. Atualmente a acurácia do método dermatoscópico para identificar câncer não melanoma fica em torno de 79% [Zambuzzi et al. 2017]. A computação vem se tornando uma forte aliada para a redução de falsos positivos e falsos negativos dando suporte ao diagnóstico médico. As técnicas de *Machine Learning* e *Deep Learning* são o estado da arte em tecnologia aplicada para medicina.

*Machine Learning* (ML) ou Aprendizado de Máquina é o ramo da Inteligência Artificial (IA) que tem como objetivo fazer as máquinas desenvolverem suas atividades de forma mais eficiente utilizando softwares inteligentes. “Os métodos de aprendizado estatístico constituem a espinha dorsal do software inteligente que é utilizado para desenvolver inteligência de máquina” [Mohammed et al. 2017].

Por ter a estatística como base, dados são essenciais para o desenvolvimento de um modelo de ML. Só é possível fazer a máquina aprender por conta própria através de dados previamente obtidos e tratados. Assim, se um sistema melhora sua performance em uma tarefa específica, quando alimentado com dados de experiências passadas, pode-se afirmar que é um exemplo de ML [Carvalho 2014].

A *Deep Learning* (DL) ou Aprendizagem Profunda é uma das áreas da ML. Segundo Perez (2017), a *Deep Learning* é uma abordagem conexionista da Inteligência Artificial, ou seja, um sistema composto de um grande número de componentes simples que juntos exibem um comportamento complexo [Perez 2017]. Lecun, Bengio e Hinton (2015) descrevem DL como métodos que permitem que modelos computacionais compostos de múltiplas camadas de processamento aprendam representações de dados com múltiplos níveis de abstração. Esses métodos são considerados o estado da arte em campos como reconhecimento de fala, reconhecimento de objetos visuais e detecção de objetos [Lecun et al. 2015].

Segundo Najafabadi et al. (2015), um dos principais benefícios da DL é a análise e o aprendizado de grandes quantidades de dados não supervisionados (sem prévia classificação), isso torna a *Deep Learning* uma ferramenta valiosa para análise de Big Data, onde os dados brutos são amplamente não rotulados e não categorizados.

Diante desse contexto, o objetivo deste trabalho é investigar a utilização de

algoritmos de *Machine Learning* ou *Deep Learning* para classificação de casos de câncer de pele com base em imagens dermatoscópicas. Essa pesquisa servirá de base para um estudo que tem como objetivo comparar a eficácia de algoritmos de ML na classificação de câncer de pele, sendo essa a principal motivação para realizá-la. A seção 2 apresenta a metodologia utilizada nesse estudo, a qual é baseada em uma Revisão Sistemática da Literatura – RSL. Após a metodologia, a seção seguinte aborda os resultados e por fim, a última seção apresenta as conclusões deste levantamento.

## **2. Metodologia**

Por se tratar de uma Revisão Sistemática de Literatura (RSL), a presente pesquisa tem caráter exploratório, pois visa o aprofundamento de um tema com base em trabalhos acadêmicos já publicados. De acordo com Kitchenham e Charters (2007), as razões ou motivos para se utilizar uma RSL vão desde a sumarização de conhecimentos acerca de determinado assunto até a identificação de lacunas no estado da arte para a sugestão de pesquisas futuras.

Ainda de acordo com o protocolo proposto por Kitchenham e Charters (2007), uma RSL é dividida em três fases: planejamento, condução e documentação.

Na fase de planejamento foi determinado qual o objetivo da revisão, resultando na especificação das questões de pesquisa, bem como nas fontes de dados onde se buscariam os estudos para compor a RSL e os critérios de inclusão e exclusão dos estudos selecionados.

Na condução utilizou-se estratégias de busca específicas para cada fonte de dados, além da leitura dos estudos encontrados, extração e tabulação dos dados destes estudos com o intuito de responder as questões de pesquisa formuladas na fase de planejamento.

A última fase, documentação, os dados tabulados na fase anterior foram analisados e as questões de pesquisas respondidas resultando em um relatório final. A seguir, cada etapa será detalhada para uma melhor compreensão.

### **2.1. Planejamento**

#### **2.1.1. Questões de pesquisa**

O objetivo da presente RSL é mapear os estudos acadêmicos a respeito da utilização de algoritmos de *Machine Learning* para classificação de casos de câncer de pele com base em imagens dermatoscópicas e assim, conforme mostrado anteriormente, criar uma base teórica para o desenvolvimento de um estudo posterior. Para alcançar este objetivo, foram definidas as seguintes questões de pesquisa a serem respondidas mediante o levantamento dos estudos:

Questão 1 (Q1) - Quais algoritmos de *Machine Learning* vêm sendo mais utilizados para classificação de casos de câncer de pele?

Questão 2 (Q2) - Quais bases de dados são utilizadas para treinar e testar os algoritmos de *Machine Learning* para classificar casos de câncer de pele?

#### **2.1.2. Fontes de dados**

Para determinar as fontes de dados utilizadas para buscar os estudos que fizeram parte da RSL, no primeiro momento foi utilizado o *Google Scholar* levando em consideração que esta ferramenta traz pesquisas de outras fontes e, com isso, foi possível fazer uma

análise das fontes mais encontradas.

Depois dessa análise inicial feita no *Google Scholar*, as fontes de dados selecionadas foram as descritas no Quadro 1.

**Quadro 1. Fontes de dados selecionadas**

Fonte de dados	Link
<i>Google Scholar</i>	<a href="https://scholar.google.com">https://scholar.google.com</a>
<i>Science Direct</i>	<a href="https://www.sciencedirect.com">https://www.sciencedirect.com</a>
<i>IEEE</i>	<a href="https://IEEEexplore.IEEE.org/Xplore/home.jsp">https://IEEEexplore.IEEE.org/Xplore/home.jsp</a>
<i>Scielo</i>	<a href="https://www.Scielo.org">https://www.Scielo.org</a>

### 2.1.3. Critérios de inclusão e exclusão

De acordo com o protocolo proposto por Kitchenham e Charters (2007), alguns critérios devem ser definidos para incluir os estudos que serão analisados e farão parte do relatório final da RSL, bem como excluir os estudos que fogem ao objetivo final da revisão e não respondem a questão de pesquisa alguma.

O Quadro 2 mostra os critérios de inclusão e exclusão levados em consideração nesta RSL para filtrar os estudos encontrados.

**Quadro 2. Fontes de dados selecionadas**

Critérios de Inclusão	Critérios de Exclusão
Artigos, tccs e monografias	Pesquisas secundárias (RSL ou MSL)
Publicado entre 2015 e 2019 <sup>2</sup>	Não aborda o câncer de pele
Informar o algoritmo	Não aborda algoritmo de classificação de imagem
Informar qual a base de dados	Pesquisa não experimental
Informar a acurácia	

## 2.2. Condução

### 2.2.1. Busca dos trabalhos

Para buscar os trabalhos nas fontes de dados selecionadas foi necessário a criação de uma *String* de busca, porém, como esta *String* não funciona em todas as fontes selecionadas, foram utilizadas adaptações necessárias.

A *String* de busca utilizada nas fontes de dados foi a seguinte:

“*Machine Learning*” or “*Deep Learning*”) and (“skin cancer” or “skin lesion”) and “images classification” and algorithms

### 2.2.2. Estratégia de seleção

A primeira busca retornou um total de 202 trabalhos das quatro fontes de dados selecionadas. A estratégia para aplicação dos critérios de inclusão (CI) e dos critérios de exclusão (CE) e seleção dos trabalhos se deu em 4 etapas: Leitura do título de cada

<sup>2</sup> Utilizou-se os últimos 5 anos devido a uma concentração maior de estudos nessa área nesse período de tempo, além de compreender o que se tem de mais atual na academia sobre o assunto.

trabalho, leitura do resumo, leitura da metodologia e leitura dos resultados e conclusão.

Após a aplicação dos CI e CE sobraram 40 estudos que se adequaram ao objetivo final desta RSL. A Tabela 1 mostra a quantidade de estudos selecionados por fonte de dados.

**Tabela 1. Quantidade de trabalhos selecionados por fonte**

Fonte de dados	Qtd de resultados	Qtd após CI e CE
<i>Google Scholar</i>	45	18
<i>Science Direct</i>	145	14
<i>IEEE</i>	12	8
<i>Scielo</i>	0	0

A planilha detalhada com o título dos trabalhos, autores, ano, base de dados, algoritmos utilizados e uma breve análise da conclusão pode ser acessada no seguinte link: <https://tinyurl.com/y3ytp5dp>

### 2.3. Documentação

Para análise e apresentação dos estudos selecionados, foram destacados, de cada um deles, os algoritmos de ML que utilizaram, bem como as bases de dados de imagens dermatoscópicas e a acurácia dos algoritmos na classificação dos casos de câncer de pele. Desta forma, foi possível identificar e quantificar o mais utilizado nos estudos selecionados, possibilitando responder às questões de pesquisas, bem como atingir o objetivo final dessa RSL.

Como ferramentas para apresentação dos resultados foram utilizados gráficos, quadros e tabelas. A próxima seção trará os resultados detalhados do estudo.

## 3. Resultados


Após o levantamento e análise dos estudos selecionados, foi possível responder as questões inicialmente propostas e alcançar o objetivo da revisão sistemática. A seguir, cada questão será respondida com dados obtidos a partir dos estudos selecionados.

### **Q1 – Quais algoritmos de *Machine Learning* vêm sendo mais utilizados para classificação de casos de câncer de pele?**

No total, 12 algoritmos diferentes foram utilizados nos 40 estudos selecionados. Alguns desses estudos utilizaram mais de um algoritmo de *Machine Learning* para classificação dos casos de câncer de pele; inclusive, em alguns deles, foi realizada uma comparação dos resultados.

O foco da questão de pesquisa Q1 é apontar os algoritmos mais utilizados nos estudos selecionados. Dos 12 algoritmos, apenas quatro foram utilizados mais de uma vez, a Figura 1 mostra esses quatro algoritmos e o percentual de utilização de cada um.

De acordo com a Figura 1 os dois algoritmos mais utilizados foram as *Convolutional Neural Networks* (CNN) e as *Support Vector Machines* (SVM).



**Figura 1. Algoritmos mais utilizados**

*Convolutional Neural Network* (CNN), ou Redes Neurais Convolucionais, são redes neurais com uma arquitetura particular que têm se mostrado bastante eficientes nos campos de reconhecimento e classificação de imagem.

As CNNs se diferenciam das Redes Neurais tradicionais pelo fato de que os neurônios das camadas escondidas da Rede Neural Convolucional não estarem conectados com todos os neurônios da camada anterior como acontece nas Redes Neurais Artificiais e sim com um pequeno número deles. As CNNs são compostas, em sua maioria, pelas seguintes camadas: camadas convolucionais, camadas de ativação, camadas de *pooling* e camada de *output* [Massucatto 2018].

De acordo com Massucatto (2018), as camadas convolucionais são responsáveis por extrair *features* (parâmetros) de cada pequena parte da camada de *input* (pixel de uma imagem, por exemplo) por meio de um determinado filtro ou kernel. Esse kernel são pequenas matrizes que realizarão o processo de convolução com os dados da camada de *input*. As camadas de ativação ou ReLU (*Rectified Linear Unit*) e camadas de *pooling*, ou agrupamento, são responsáveis por simplificar a saída realizando um *downsampling* não-linear, reduzindo o número de parâmetros que a rede precisa aprender e assim minimizando a probabilidade de *overfitting* [Vargas et al. 2016]. Por fim, a camada de *output* é composta por algumas subcamadas responsáveis por classificar o que foi aprendido, ou seja, determinar a que classe previamente definida aquele dado (uma imagem, por exemplo) pertence. Alguns exemplos de subcamadas da camada de *output* são as camadas de *flatten*, de *fully connected* (esta é uma Rede Neural Artificial dentro da CNN) e *Softmax*.

As *Support Vector Machines* (SVM), ou Máquinas de Vetores de Suporte, assim como as Redes Neurais Convolucionais também são amplamente utilizadas na análise e classificação de imagens.

A SVM utiliza aprendizado supervisionado, com métodos estatísticos não probabilísticos e tem como objetivo encontrar um classificador linear capaz de separar classes de acordo com as semelhanças de características determinadas previamente [Lorena e Carvalho 2007]. Esse classificador linear é conhecido como hiperplano e ele busca maximizar a distância entre os pontos mais próximos em relação a cada uma das classes.

Assim, um algoritmo SVM, treinado com um conjunto de dados onde cada registro tem especificado suas devidas *features* (características) e *labels* (classificação), calculará um separador linear (hiperplano) capaz de classificar um novo dado de acordo com suas características. O Quadro 3 lista todos os 12 algoritmos utilizados nos estudos.


**Quadro 3. Algoritmos utilizados para classificação de casos de câncer de pele**

Algoritmos	Refs dos artigos	N <sup>o</sup> de citações
<i>Convolutional Neural Network</i> (CNN)	[A04], [A06], [A07], [A08], [A11], [A12], [A15], [A17], [A18], [A19], [A20], [A21], [A22], [A23], [A24], [A25], [A28], [A29], [A34], [A35], [A37], [A39]	22
<i>Support Vector Machine</i> (SVM)	[A05], [A06], [A07], [A10], [A34], [A35], [A40]	7
Neural Network (NN)	[A01], [A14], [A16], [A40]	4
Fish Vector (FV)	[A07]	1
Artificial bee colony (ABC)	[A09]	1
Multiple Instance Learning (MIL)	[A13]	1
Adaptive-Network-based Fuzzy Inference System	[A16]	1
Multi-Channel-ResNet	[A26]	1
Fuzzy C-mean	[A28]	1
ResNet	[A33], [A35], [A38]	3
AlexNet	[A38]	1
KNN	[A40]	1

**Q2 – Quais bases de dados são utilizadas para treinar e testar os algoritmos de *Machine Learning* para classificar casos de câncer de pele?**

O conjunto ou base de dados é parte fundamental para treinar um bom modelo de ML. Oito bases de dados foram encontradas durante a leitura e análise dos estudos selecionados. Alguns dos estudos não informaram a base utilizada para treinar o modelo de ML e outros utilizaram *Transfer Learning*, reutilizando modelos pré-treinados com bases de dados desconhecidas, para classificar as imagens.

Com relação à utilização das bases de dados, notou-se que cinco das oito foram utilizadas em mais de um estudo. A Figura 2 mostra quais são essas bases e um percentual de utilização de cada uma nos estudos selecionados para compor a fonte de dados dessa RLS.



**Figura 2. Bases de dados mais utilizadas**

O *International Skin Imaging Collaboration* (ISIC), base de dados mais utilizada nos estudos, é um projeto que visa melhorar os diagnósticos de melanoma e reduzir a mortalidade desse tipo de câncer. O ISIC é um *dataset* de acesso público de código aberto de imagens de lesões na pele para testes e validações. Esta base de dados serve como um recurso público de imagens para o ensino e para o desenvolvimento e teste de sistemas de diagnóstico automatizados.

Atualmente o *dataset* disponibilizado pelo ISIC possui mais de 23.900 imagens devidamente classificadas.

A segunda base de dados mais utilizada foi o PH2 *dataset*. Este *dataset* conta com um banco com imagens dermatoscópicas obtido do Serviço Dermatológico do Hospital Pedro Hispano. O PH2 *dataset* é parte do projeto PH2 que conta com médicos doutores do Hospital Pedro Hispano e pesquisadores de diversos campos da Engenharia e Matemática das Universidades do Porto, de Aveiro e do Instituto Superior Técnico.

As imagens contidas nessa base de dados são classificadas e todas são coloridas, com 8-bit de tamanho e resolução de 768x56. No total, são 200 imagens dermatoscópicas de lesões na pele disponibilizadas no PH2 *dataset*.

O ISIC e o PH2 *dataset* foram as bases de dados mais utilizadas para treinar e testar os algoritmos de *Machine Learning* dos estudos selecionados que tinham como objetivo classificar os casos de câncer de pele.

O Quadro 4 lista as sete bases de dados citadas nos estudos que foram utilizadas para treinar e testar os algoritmos de ML na classificação de casos de câncer de pele.

**Quadro 4. Base de dados utilizados para treinar os algoritmos de *Machine Learning***

Bases de dados	Refs dos artigos	N <sup>o</sup> de citações
<i>International Skin Imaging Collaboration</i> (ISIC)	[A04], [A05], [A06], [A10], [A11], [A14], [A18], [A20], [A21], [A25], [A26], [A28], [A29], [A30], [A38]	15
PH2	[A05], [A09], [A12], [A27], [A32]	5
Derm (IS and Quest)	[A06], [A09], [A16]	3
MED-NODE	[A06], [A14]	2
HAM10000	[A03]	1
<i>Regional dermatohistopathologic institute</i>	[A22]	1
ImageNet (ILSVRC)	[A24]	1

#### 4. Conclusão

A presente pesquisa apresenta os resultados de uma RSL acerca de trabalhos publicados nos últimos cinco anos centrados na utilização de algoritmos de *Machine Learning* ou *Deep Learning* para classificação de casos de câncer de pele com base em imagens dermatoscópicas. O *Google Scholar*, no primeiro momento, a *Science Direct*, o *IEEE* e a *Scielo* foram as fontes utilizadas para buscar os estudos relacionados ao tema da RSL. Após a utilização de uma *String* de Busca e da aplicação dos CIs e dos CEs, 40 estudos



foram selecionados para fazer parte da pesquisa.

Os resultados da análise desses estudos mostraram que vários algoritmos são utilizados para classificar casos de câncer de pele com base nas imagens dermatoscópicas. Os mais utilizados são as Redes Neurais Convolucionais, ou CNN, e as Máquinas de Vetores de Suporte, ou SVM, que somam juntos mais da metade da utilização dos demais algoritmos citados nos estudos selecionados.

Já com relação às bases de dados utilizadas para treinar e testar os algoritmos, apesar de muitos estudos não informarem uma base específica, trabalhando com *Transfer Learning*, e outros utilizarem bases fechadas, impossibilitando a reprodutibilidade, a maior parte dos estudos que informaram a base de dados optou pela utilização da já amplamente difundida ISIC – base que conta com mais de 20 mil imagens dermatoscópicas de lesões na pele devidamente classificadas. A segunda base de dados mais utilizada nos estudos selecionados foi a PH2 *Database* que conta com 200 imagens dermatoscópicas também devidamente classificadas.

Desta forma, esta revisão sistemática da literatura mostrou o que tem de mais atual no meio acadêmico na área de *Machine Learning* para classificação de imagem com foco no diagnóstico de câncer de pele. Esta RSL poderá servir como base para o desenvolvimento de novas abordagens, bem como para comparações entre as abordagens que existem hoje. Com isso em mente, pretende-se aumentar o escopo deste estudo por comparar algoritmos diferentes em uma mesma base de dados com o objetivo de aprofundar mais os conhecimentos a respeito.

## Referências

- CARVALHO, H. M. Aprendizado de máquina voltado para mineração de dados: árvores de decisão. Monografia submetida ao curso de graduação em (Engenharia de Software) da Universidade de Brasília. 2014.
- INCA. *Câncer de pele melanoma*. 2018. Disponível em: (<https://www.inca.gov.br/tipos-de-cancer/cancer-de-pele-melanoma>). Acesso em: 08-06-2019.
- ISIC. *About ISIC*. 2019 Disponível em: (<https://www.isic-archive.com/#!/topWithHeader/tightContentTop/about/isicArchive>). Acesso em: 08-06-2019.
- KITCHENHAM, B.; CHARTERS, S. Guidelines for performing systematic literature reviews in software engineering. In: *Technical report*, Ver. 2.3 EBSE *Technical Report* EBSE. [S.l.]: Epidemiol. Serv. Saúde, 2007.
- LECUN, Y.; BENGIO, Y.; HINTON, G. *Deep Learning*. In: Nature: Internacional Journal of Science. [S.l.]: Nature, 2015. v. 521, p. 436–444.
- LORENA, A. C.; CARVALHO, A. C. P. L. F. de. Uma introdução às *Support Vector Machines*. In: Revista de Informática Teórica e Aplicada - RITA. [S.l.]: Revista de Informática Teórica e Aplicada - RITA, 2007. v. 14, p. 43–67.
- MASSUCATTO, J. D. P. Aplicação de conceitos de redes neurais convolucionais na classificação de imagens de folhas. Trabalho de Conclusão de Curso 1, apresentado ao Curso de Engenharia de Computação da Universidade Tecnológica Federal do Paraná - UTFPR, Câmpus Pato Branco. 2018.
- MOHAMMED, M.; KHAN, M. B.; BASHIER, E. B. M. *Machine Learning: Algorithms and Applications*. [S.l.]: Taylor Francis Group, 2017.

- NAJAFABADI, M. M. et al. *Deep Learning* applications and challenges in big data analytics. In: Journal of Big Data. [S.l.]: Journal of Big Data, 2015. v. 2, cap. 1.
- PEREZ, C. E. *The Deep Learning AI Playbook: Strategy for Disruptive Artificial Intelligence*. [S.l.]: I.M. Intuition Machine, 2017.
- PH2dataset. PH2 dataset. 2019. Disponível em: (<https://www.fc.up.pt/addi/ph2/%20Database.html>). Acesso em: 08-06-2019.
- SBD. Câncer de pele: O que é? 2019. Disponível em: (<https://www.sbd.org.br/dermatologia/pele/doencas-e-problemas/cancer-da-pele/64/>). Acesso em: 08-06-2019.
- VARGAS, A. C. G.; CARVALHO, A. M. P.; VASCONCELOS, C. N. Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres. In: Proceedings of the XXIX Conference on Graphics, Patterns and Images. [S.l.: s.n.], 2016. Instituto de Computação, Universidade Federal Fluminense, Niteroi, Brasil.
- ZAMBUZZI, I. M.; VIDAL, C. H. L.; PESSANHA, A. C. A. F. Análise do índice de acurácia diagnóstica e terapêutica baseado na dermatoscopia do câncer da pele não melanoma. In: Surgical and Cosmetic Dermatology. São Paulo: Sociedade Brasileira de Dermatologia, 2017. v. 9, cap. 3, p. 224–227.