



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES  
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

## **FRAMEWORK DE MACHINE LEARNING PARA BUSCA DE MELHORES PARÂMETROS EM ALGORITMOS DE RESTAURAÇÃO DE IMAGENS**

**RELATÓRIO FINAL DE PROJETO DE INICIAÇÃO CIENTÍFICA  
(PIBIC/INPE/CNPq)**

**Gabriel Tobias Fuhr (Universidade Federal de Santa Maria, Bolsista  
PIBIC/CNPq)  
E-mail: [gtfuhr@inf.ufsm.br](mailto:gtfuhr@inf.ufsm.br)**

**João Vicente Ferreira Lima (Informática-UFSM, Orientador)  
E-mail: [jvlima@inf.ufsm.br](mailto:jvlima@inf.ufsm.br)**

**Haroldo de Campos Velho (LABAC/COCTE/INPE, Orientador)  
E-mail: [haroldo.camposvelho@inpe.br](mailto:haroldo.camposvelho@inpe.br)**

Julho de 2019



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES  
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

## FRAMEWORK DE MACHINE LEARNING PARA BUSCA DE MELHORES PARÂMETROS EM ALGORITMOS DE RESTAURAÇÃO DE IMAGENS

Gabriel Tobias Fuhr

Relatório final de projeto de iniciação científica sob orientação  
do Dr. João Vicente de Ferreira Lima  
e do Dr. Haroldo de Campos Velho

Julho de 2019



## SUMÁRIO

RESUMO .....	4
LISTA DE SÍMBOLOS E ABREVIATURAS .....	5
INTRODUÇÃO .....	6
OBJETIVOS DO TRABALHO .....	6
FUNDAMENTAÇÃO TEÓRICA .....	7
MATERIAIS E MÉTODOS UTILIZADOS .....	8
ANÁLISES E RESULTADOS .....	9
CONCLUSÕES .....	14
REFERÊNCIAS BIBLIOGRÁFICAS .....	15



## RESUMO

Uma das importantes atividades no ramo de pesquisa Aeroespacial é a de capturar imagens através de câmeras e sensores aerotransportados por aviões e satélites. Tais imagens podem ter alterações com incorporação de ruídos externos durante a sua captura. Procurando suavizar efeitos negativos causados pelos ruídos, o tratamento de imagens, ramo da Ciência da Computação, é utilizado para remover em parte os ruídos de imagens. Técnicas para restaurar as imagens, gerando imagens próximas à realidade, representam um avanço significativo para áreas que fazem uso de imagens que requerem nitidez e precisão. Destas áreas, destacam-se aplicações em astronomia, sensoriamento remoto, ciências dos materiais, ciências geofísicas, biologia e medicina, para citar algumas áreas, onde informações quantitativas precisas são importantes para ciência da área e desenvolvimento tecnológico. Também pode-se notar a importância da remoção de ruídos em algoritmos de posicionamento de Veículos Aéreos Não Tripulados (VANTs), onde a nitidez das imagens capturadas é crucial para garantir que o VANT conseguirá se localizar utilizando um banco de imagens georreferenciadas. São várias as técnicas utilizadas na restauração de imagens. De fato, inúmeros algoritmos de restauração de imagens já foram desenvolvidos e implementados. A implementação algorítmica consiste em codificar o método de restauração em específico em uma série de passos em linguagem computacional. O algoritmo deve receber como parâmetro a imagem a ser restaurada, algumas soluções algorítmicas apresentam mais parâmetros, como o Bayes-Shrink. Os parâmetros citados anteriormente, causam efeitos no resultado final da execução de uma restauração, por isso sua escolha deve ser feita de maneira a maximizar os resultados de uma correção de ruídos. Pensando nisso, utilizar-se-á técnicas de *Machine Learning*, área da computação onde dados são fornecidos ao computador para o mesmo gerar soluções ou *insights* sobre os dados, como forma de escolha desses parâmetros. Os dados seriam um banco de imagens originais e imagens alteradas por ruído (Imagens e histogramas) e um algoritmo a ser especificado pelo utilizador da plataforma. Com isso, a plataforma iria devolver um modelo de *Machine Learning* como um previsor de parâmetro ideal para uma dada imagem desconhecida e o algoritmo em questão. Fazendo com que a escolha do parâmetro deixe de ser um processo empírico da escolha do pesquisador, para ser uma escolha baseada em dados para maximizar a eficiência do algoritmo de restauração de imagens.



## LISTA DE SÍMBOLOS E ABREVIATURAS

INPE – Instituto Nacional de Pesquisas Espaciais

VANT – Veículo Aéreo Não Tripulado

PSNR – Com o significado de *Peak Signal-to-Noise Ratio*, o PSNR é um termo utilizado na engenharia para definir a relação entre a máxima energia de um sinal e o ruído que afeta sua representação original, ou seja antes do sinal ter sofrido algum tipo de ruído.



## INTRODUÇÃO

Tratamento de imagens é usado em diversas áreas da ciência e tecnologia. Deste modo, é importante que a restauração dos sinais seja eficiente para que os cientistas tenham um bom material de pesquisa a ser utilizado. Pensando nisso, a comunidade acadêmica vem criando diversos filtros de ruídos de imagens, que foram estudados na parte inicial dessa pesquisa. Tais filtros podem ter algum tipo de parâmetro que influencia a qualidade final da imagem restaurada.

A identificação dos melhores parâmetros citados associado a alguma técnica desempenham um papel importante neste trabalho. Técnicas como o *Gradient Descent* (ROBBINS; MONRO, 1951) podem ser utilizadas para descobrir de maneira iterativa o melhor parâmetro para uma determinada imagem. Fazendo esse processo com várias imagens, pode-se criar um banco de dados de imagens com essas imagens sendo associadas ao seu parâmetro ideal para o seu uso em um filtro de ruídos.

Com este banco de dados completamente processado, o mesmo pode ser utilizado para treinar um modelo de *Machine Learning*, um algoritmo que permite ao computador encontrar padrões em dados após processar um banco de dados de exemplo. A forma utilizada pela presente pesquisa para estudar as técnicas e filtros citados anteriormente está presente nas seguintes seções.

## OBJETIVOS DO TRABALHO

Este trabalho de pesquisa tem por finalidade aprimorar o resultado obtido na restauração de imagens (BERTERO e BOCCACCI, 1998), visto que o tratamento de imagens é uma atividade importante para as tarefas sendo realizadas no INPE, como explicado nesta seção. Tal meta de aprimorar o tratamento de imagens, pretende-se ser atingida através da realização dos seguintes objetivos.

Aproveitar os conhecimentos obtidos durante a pesquisa que foi realizada, pelo estudante Vinicius Schmidt Monego, que aprimorou a plataforma de restauração de imagens *webfriends* disponível em: <http://webfriends.herokuapp.com/>. O relatório das atividades feitas por Vinicius Manego encontra-se disponível em anexo – a presente pesquisa dá continuidade à investigação iniciada por Monego.

Diferentes técnicas computacionais podem ser úteis em restauração de imagens. Neste trabalho, é possível observar a utilização de *Machine Learning* no tratamento de imagens e filtragem de ruídos. O emprego de novas metodologias serve para motivar os pesquisadores envolvidos com o uso e desenvolvimento de novas ferramentas na área de Ciência de Computação para o tratamento de imagens.

Explorar e testar o uso de *Machine Learning* no processo de restaurar imagens tem crescido na ciência e na indústria. A técnica de *Machine Learning* (ML), com seu poder de encontrar padrões, é utilizada frequentemente no mercado de ações e em grandes empresas de Computação (Google, Facebook, Amazon e Alibaba são alguns exemplos), pode ser utilizado no momento de escolher os melhores parâmetros em algoritmos usados na restauração de imagens.

Fazer o uso das técnicas de ML é um dos objetivos da presente pesquisa e também criar uma solução aplicável que possa ser usada por outros pesquisadores. Ferramentas



como *Github*<sup>1</sup>, para a disponibilização do código-fonte do projeto, e da plataforma *DockerHub*<sup>2</sup>, para a distribuição de uma instância de desenvolvimento do mesmo, permitem o compartilhamento e colaboração por pesquisadores, mesmo que não participem da presente pesquisa.

Avaliação da metodologia proposta será por uma série de testes.

## FUNDAMENTAÇÃO TEÓRICA

Uma das principais atividades do INPE consiste em analisar imagens astronômicas em suas pesquisas. Para que um bom resultado seja obtido pelos pesquisadores, espera-se que os dados que estejam sendo alvos do estudo ou análise tenham uma boa qualidade.

Outra atividade que explora o uso de imagens capturadas em situações diversas é o uso de VANTS. Autores tem desenvolvido estratégias para navegação autônoma de VANTS baseadas em processamento de imagens (CONTE e DOHERTY, 2008; GOLTZ et al., 2011). Imagens são capturadas durante o trajeto do VANT e, após várias etapas de processamento, são comparadas com o mapa da região, com objetos de cena georeferenciados, para localizar o veículo na trajetória planejada do voo.

Dados obtidos por sensores contém imprecisões e são contaminados por ruídos. Tais dispositivos podem ser câmeras e diferentes sensores – barômetros, anemômetros, giroscópios, entre outros (BRAGA et al., 2018).

Os ruídos podem gerar imperfeições nas imagens utilizadas em diversas aplicações e/ou durante a utilização de imagens durante a operação/navegação de VANTS. Com isso, é necessária a pesquisa e a investigação de técnicas para obter imagens de alta qualidade, resultante do tratamento das mesmas.

A literatura consultada apresenta diferentes soluções para encontrar o algoritmo e seu parâmetro de melhor resultado, como usado por Kozakevicius e Bayer (2014): Bayeshrink (CHANG et al, 2000) e Visushrink (DONOHO; JOHNSTONE, 1994).

Como visto em (MORGAN, 2018), o uso do *Machine Learning* tem sido benéfico a diferentes áreas do conhecimento, graças a sua característica de permitir que seja possível extrair importantes informações e padrões de dados como imagens, documentos, vídeos e tabelas. As técnicas usadas se tornaram viáveis graças ao grande aporte de dados de todo o tipo de fontes, em consonância ao aumento do poder computacional dos últimos anos, tudo isso tem trazido soluções inovadoras para a sociedade. Tais soluções podem ser utilizadas em tarefas como o reconhecimento de voz, compra e venda de ações, desenvolvimento de carros autônomos e até mesmo diagnósticos de saúde mais precisos.

Desta forma, o uso de *Machine Learning* no reconhecimento e identificação de relações e padrões, como explorado por Bishop e Christopher (2016), pretende-se criar uma solução que permita os pesquisadores fazerem uso do poder computacional disponível e dos métodos de *Machine Learning* para criar um modelo que encontrará o parâmetro ideal para certo algoritmo de tratamento de imagens. Entende-se como parâmetro ideal, aquele que possui o melhor resultado possível na realização do tratamento de imagens.

Para a realização dos testes e para o treinamento do modelo de *Machine Learning*, se usará o atributo PSNR, com sua validade neste tipo de teste verificada em (HUYNH-THU; M. GHANBARI, 2008), também utilizado com parâmetro de teste em (KOZAKEVICIUS; BAYER, 2014) e em (SCHMIDT; ROTH, 2013). O atributo de PSNR

---

<sup>1</sup> [www.github.com](http://www.github.com)

<sup>2</sup> [www.dockerhub.com](http://www.dockerhub.com)

desempenha o papel de servir como parâmetro da qualidade de uma imagem restaurada em comparação com a imagem original. Ele possui uma relação de ser um número maior quando a imagem restaurada trazer resultados positivos e um número menor caso o resultado não seja tão satisfatório, como no resultado de um tratamento que pode ser encontrado a seguir.

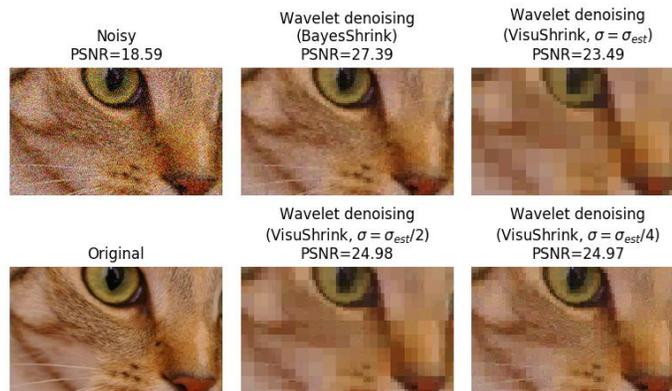


Figura 1: Exemplo da utilização do atributo PSNR.

## MATERIAIS E MÉTODOS UTILIZADOS

Para o estudo inicial da área de tratamento de imagens, a presente pesquisa fez o uso das conclusões encontradas em (KOZAKEVICIUS; BAYER, 2014), empregando técnicas *Wavelet* e algoritmos para determinar o melhor parâmetro para aplicação de interesse, dentre eles, os algoritmos *BayeShrink* e o *VisuShrink*. Estes algoritmos dependem de um parâmetro a ser definido pelo seu utilizador e o valor do parâmetro influencia na qualidade do tratamento de imagem.

Estudou-se também o uso da técnica de *Gradient Descent*, suas variações e alternativas. A primeira foi definida em (ROBBINS; MONRO, 1951) e implementação utilizada em (KIEFER; WOLFOWITZ, 1952).

Como bibliografia auxiliar para o estudo das técnicas de *Machine Learning*, utilizou-se o texto de Géron (2017), que ensina ao leitor como utilizar a biblioteca Tensorflow para aplicar otimizadores de variáveis como o *Gradient Descent* e outras alternativas. É interessante ressaltar que a pesquisa buscará diferentes alternativas de otimizadores para obter um melhor resultado e desempenho, pois alguns desses otimizadores possuem vantagens e desvantagens. O *Gradient Descent*, por exemplo, possui o problema de não encontrar o parâmetro ideal quando existem multiplicidade de mínimos locais e/ou quando a região do espaço de busca é um hiper-plano. Como este problema pode ser encontrado durante o desenvolvimento da solução a ser implementada, irão ser exploradas as diferentes alternativas oferecidas pela biblioteca *Tensorflow*<sup>3</sup>, como as citadas a seguir:

- *Stochastic Gradient descent with gradient clipping*

<sup>3</sup> www.tensorflow.org



- *Momentum*
- *Nesterov momentum*
- *Adagrad*
- *Adadelta*
- *RMSProp*
- *Adam*
- *Adamax*
- *SMORMS3*

Todas essas diferentes técnicas alternativas ao *Gradient Descent* padrão, encontram-se disponíveis na *documentação*<sup>4</sup> da biblioteca supracitada. As diferentes características, como vantagens e desvantagens das alternativas mencionadas são encontradas em (RUDER, 2016).

Como citado na Fundamentação Teórica do presente trabalho, uma solução usando *Machine Learning* será implementada para encontrar os melhores parâmetros para algoritmos de tratamento de imagens. Para isso ser formulado, as seguintes técnicas foram estudadas.

*Gradient Descent* (ROBBINS; MONRO, 1951) é uma técnica para encontrar o parâmetro ideal para cada imagem a ser analisada pelo algoritmo de *Machine Learning*. Cada imagem do banco de dados é processada via *Gradient Descent*, que determina o parâmetro que produz o maior PSNR.

Utilizando a técnica supracitada, cada imagem do banco de dados terá um parâmetro ideal associado a mesma. Em outras palavras, o banco de dados possuirá dados com *labels* (etiquetas, em português), ou seja, cada imagem possuirá um valor associado a mesma. Essa forma de organizar informações é vista no treinamento de algoritmos de *Machine Learning* supervisionados, onde os algoritmos recebem os dados e os valores associados.

A solução a ser desenvolvida é do tipo supervisionada, visto que os dados atrelados a cada imagem são dados na seção de treinamento do modelo de Inteligência Artificial. Uma importante fonte de material a ser utilizada é o banco de imagens *imagenet*<sup>5</sup> (RUSSAKOVSKY et al, 2015), utilizado por diferentes trabalhos realizados na literatura e na indústria da computação. A solução final terá o formato de um algoritmo de regressão, onde o modelo treinado, após o treinamento com os dados descritos anteriormente, terá como entrada uma imagem desconhecida e será calculado o parâmetro ideal para o tratamento da imagem com o algoritmo especificado pelo utilizador da solução.

## ANÁLISES E RESULTADOS

O algoritmo *BayeShrink*, tem como característica o fato de a escolha de seu parâmetro ser feita de forma adaptativa, para cada parte da imagem sendo tratada, já no caso do algoritmo *VisuShrink* utiliza-se um parâmetro universal para o tratamento da imagem. Para o último parâmetro ser escolhido, deve-se seguir as orientações em (DONOHO e JOHNSTONE, 1994) para se encontrar o parâmetro ideal, segundo os

<sup>4</sup> [www.tensorflow.org/api\\_docs/python/tf/train/](http://www.tensorflow.org/api_docs/python/tf/train/)

<sup>5</sup> [www.image-net.org/](http://www.image-net.org/)

autores. Porém, observou-se através da realização de testes que variavam o valor encontrado, que é possível encontrar um parâmetro com resultados melhores no tratamento do que os resultados obtidos com o parâmetro obtido através da técnica citada em (DONOHO e JOHNSTONE, 1994).

Pensando em explorar mais essa característica encontrada no método *VisuShrink*, o presente trabalho apresenta a seguinte proposta, que consiste em montar um banco de dados com imagens, providas do banco de imagens *ImageNet*, e seus parâmetros ideais, encontrados através da utilização de uma variação do algoritmo de *Gradient Descent*. Cada parâmetro ideal será encontrado como está sendo explicado na Figura 2.

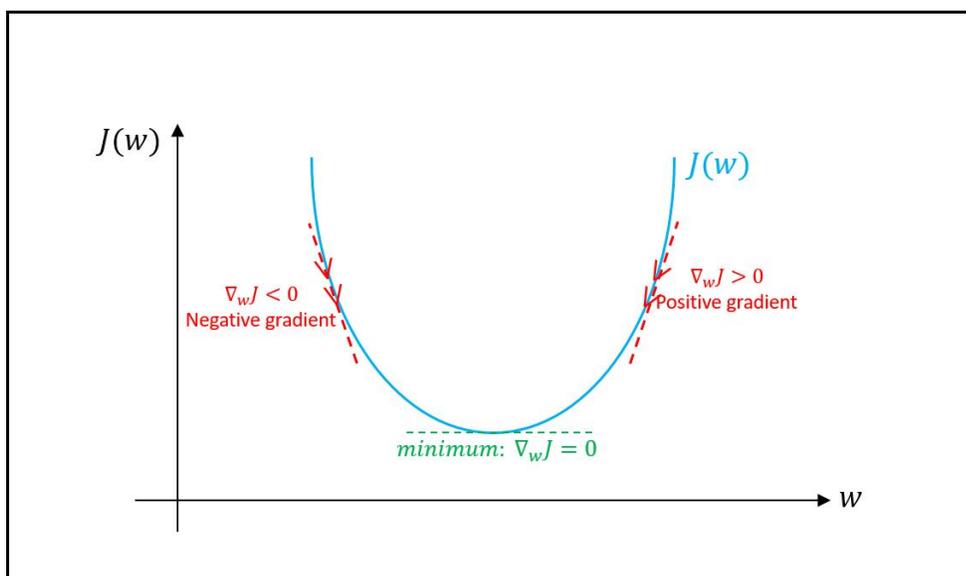
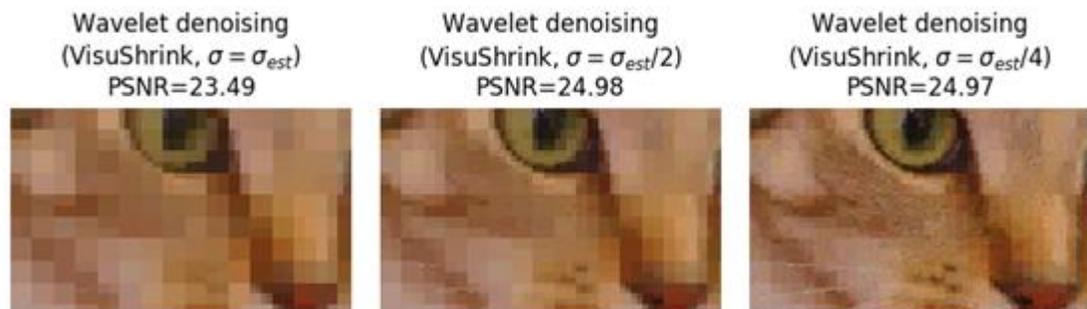


Figura 2: Descrição do funcionamento do *Gradient Descent*.

Foi implementada uma versão simplificada do *Gradient Descent*, utilizada para obter um parâmetro ideal para o tratamento de uma imagem, que pode ser definida segundo os seguintes passos, vale ressaltar que os passos a seguir contém descrições de suas funções:

1. É feita a escolha de uma imagem a ser utilizada na busca de um parâmetro ideal, tal imagem possuirá duas instâncias, uma instância com as características originais da imagem e outra instância que sofreu um ruído gaussiano com o desvio padrão definido em 0,1.
2. Com a imagem alterada disponível, pode-se obter o sigma estimado normalmente utilizado para o algoritmo *Visushrink* através da função “*estimate\_sigma*”<sup>6</sup>, presente no módulo *Restoration* da biblioteca *sci-kit image*, o sigma estimado será usado como o parâmetro universal (*Threshold*) do algoritmo *Visushrink*. Esse *Threshold* estimado segundo os passos descritos em (DONOHO e JOHNSTONE, 1994) é conhecido por remover todo o ruído da imagem, porém, o mesmo ( $\sigma_{est}$  na imagem) também costuma produzir imagens muito suavizadas como visto na figura abaixo.

<sup>6</sup> [https://scikit-image.org/docs/dev/api/skimage.restoration.html#skimage.restoration.estimate\\_sigma](https://scikit-image.org/docs/dev/api/skimage.restoration.html#skimage.restoration.estimate_sigma)



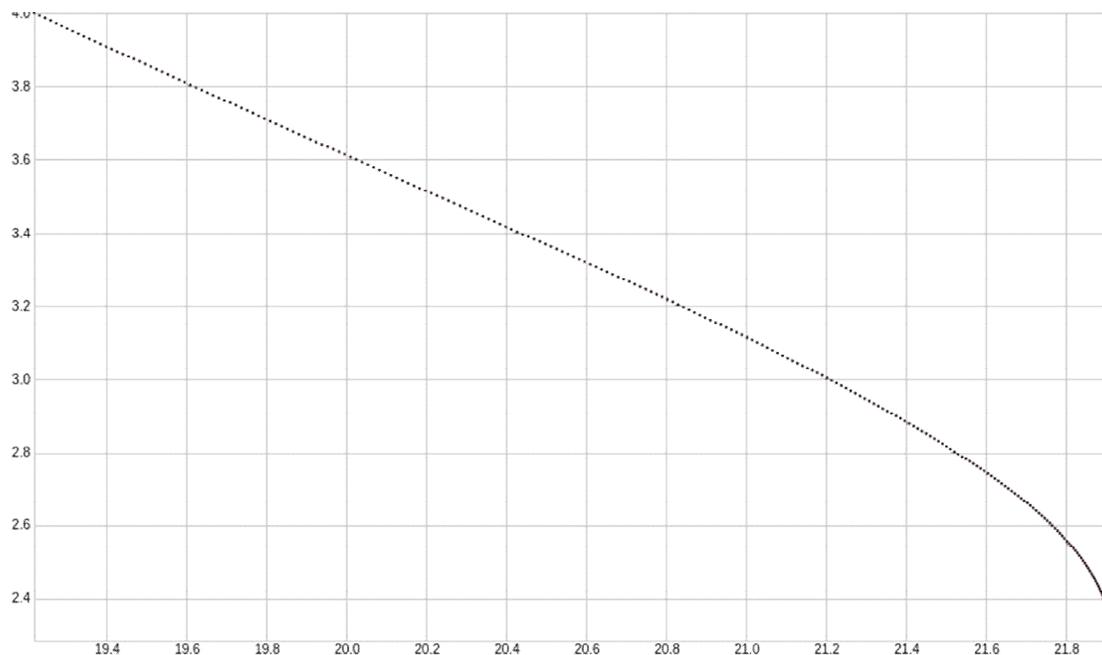
**Figura 3: Diferentes resultados obtidos através da variação do  $\sigma_{est}$  obtido originalmente através da função *estimate sigma*<sup>7</sup> da biblioteca scikit-image, com a função sendo baseada na técnica descrita em (DONOHO e JOHNSTONE, 1994).**

3. O sigma estimado (Novamente,  $\sigma_{est}$  na imagem) por padrão suaviza muito a imagem, fazendo com que perca algumas de suas características originais. Pensando nesse problema, alguns exemplos do uso do *Visushrink* variam o sigma estimado o dividindo por diferentes números, como 2 ( $\sigma_{est}/2$  na imagem) e 4 ( $\sigma_{est}/4$  na imagem), obtendo diferentes resultados do que os obtidos através do sigma original. Considerando isso, decidiu-se que o número que dividirá o sigma estimado padrão será encontrado através de um otimizador de parâmetros, como o descrito em mais detalhes nos próximos passos.
4. Para se obter o parâmetro ideal, sendo definido como ( $\sigma_{est}/$ parâmetro ideal) utilizou-se como função de utilidade o PSNR (Quanto maior o seu valor, melhor o resultado obtido). As variáveis utilizadas na versão simplificada do Gradient Descent que foi utilizada para descobrir o parâmetro ideal são definidas a seguir:
  - “c” define o parâmetro ideal, com o seu valor inicial sendo arbitrariamente definido em 4.
  - “*learning rate*” define a taxa de aprendizado a ser utilizada, quanto maior a taxa de aprendizado mais rápido os valores irão variar, porém é possível que com uma taxa de aprendizado muito grande o ponto de mínimo ruído seja ignorado pelo algoritmo. O valor da taxa de aprendizado foi definido em 0,0001
  - “*learning direction*” define a direção do aprendizado, podendo assumir o valor -1 para o ajuste da variável tender ao infinito negativo com o passo do tamanho da *learning rate* e 1 para tender ao infinito positivo. O valor inicial da direção do aprendizado é -1, tendendo aos números negativos.
  - “*epochs*” define o número de épocas do algoritmo, ou seja, o número de vezes que o passo de otimização do parâmetro ideal descrito a seguir será executado.

<sup>7</sup> [https://scikit-image.org/docs/dev/api/skimage.restoration.html#skimage.restoration.estimate\\_sigma](https://scikit-image.org/docs/dev/api/skimage.restoration.html#skimage.restoration.estimate_sigma)

5. Trata a imagem usando o *Visushrink* e o parâmetro  $c$  pela primeira vez.
6. Repetir o seguinte passo  $n$  vezes,  $n$  sendo definido com o valor da variável “*epochs*”: Trata a imagem usando o *Visushrink* e o parâmetro  $c$  atualizado de acordo com a *learning rate* ( $c = c + learning\ direction * learning\ rate$ ), caso o PSNR cresça, a direção de aprendizado é mantida, caso contrário, o sinal do mesmo é invertido.
7. Exibe o melhor PSNR obtido e seu parâmetro  $c$  correspondente ao usuário
8. Fim do algoritmo.

Para fins de teste, foi realizada uma bateria com 300 épocas de tratamentos e comparações usando a *variação simples*<sup>8</sup> do *Gradient Descent* mostrada anteriormente, disponível no repositório<sup>9</sup> *Github* da presente pesquisa, o  $\sigma$  foi obtido através da função *estimate sigma*<sup>10</sup>. O parâmetro a ser otimizado é representado no eixo vertical da figura a seguir, o  $\sigma$  é dividido pelo parâmetro durante os testes no algoritmo *Visushrink*. O algoritmo foi variando o dado de interesse, até que o PSNR atingisse um ponto máximo, aumentando a qualidade da imagem restaurada.



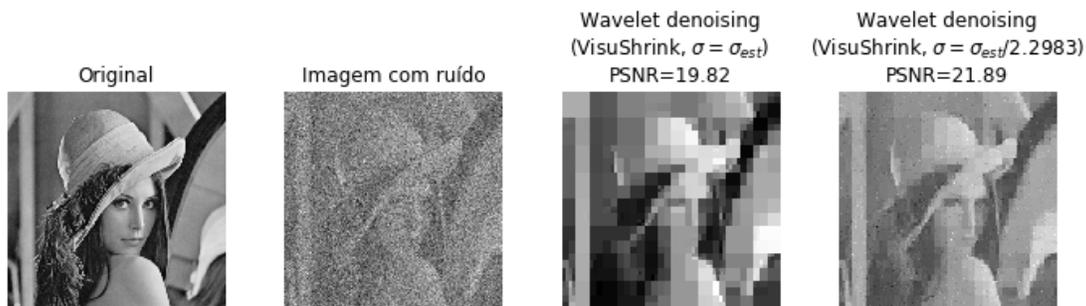
**Figura 4: Gráfico com os dados do teste realizado e descrito anteriormente, onde o PSNR está sendo representado no eixo horizontal e a variável a ser otimizada no eixo vertical.**

A figura 4 demonstra os dados dos testes realizados, com o PSNR sendo representado no eixo horizontal e a variável a ser otimizada no eixo vertical, utilizou-se o PSNR como a função utilidade (Quanto maior o seu valor, melhor). A bateria de testes é realizada até o momento em que o PSNR não aumenta mais o seu valor. O protótipo de implementação descrito anteriormente não prevê a multiplicidade de locais mínimos.

<sup>8</sup>[github.com/gtfuhr/machine\\_learning\\_framework\\_for\\_image\\_restoration/blob/master/pythonDenoise/gradientDescent.py](https://github.com/gtfuhr/machine_learning_framework_for_image_restoration/blob/master/pythonDenoise/gradientDescent.py)

<sup>9</sup>[github.com/gtfuhr/machine\\_learning\\_framework\\_for\\_image\\_restoration](https://github.com/gtfuhr/machine_learning_framework_for_image_restoration)

<sup>10</sup>[https://scikit-image.org/docs/dev/api/skimage.restoration.html#skimage.restoration.estimate\\_sigma](https://scikit-image.org/docs/dev/api/skimage.restoration.html#skimage.restoration.estimate_sigma)



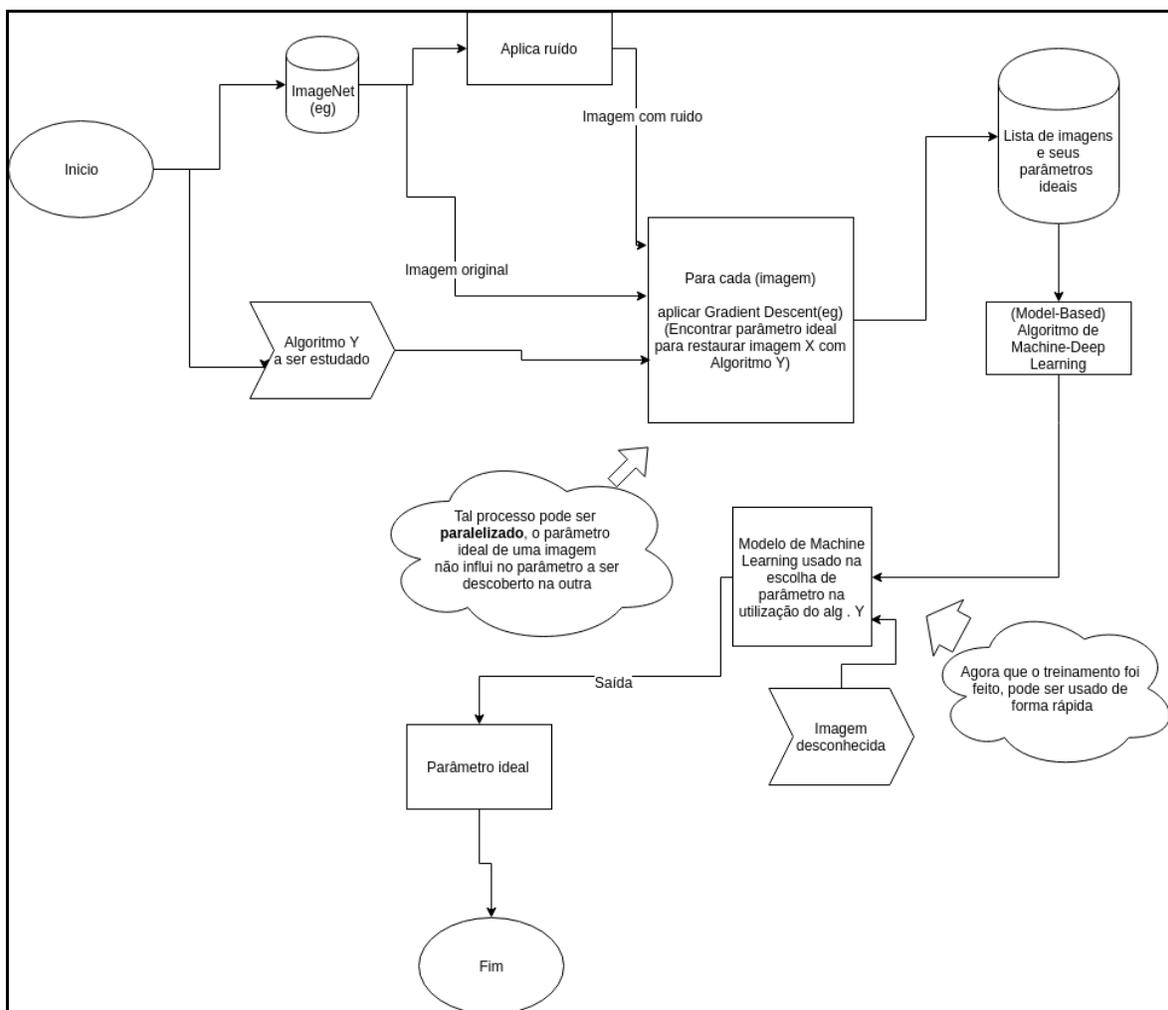
**Figura 5: Comparação do resultado obtido com o sigma estimado original, na terceira imagem, com o sigma estimado dividido pelo parâmetro ideal encontrado (2.2983) na quarta imagem.**

Essa execução é um exemplo com um protótipo de otimizador de parâmetro e algoritmo de restauração são escolhidos, de como poderia ser feito o processamento de uma imagem do banco de dados: o banco guardaria a imagem e o parâmetro com melhor PSNR após o tratamento da imagem. Com o Banco de Dados de imagens associadas a seus parâmetros ideais completo, tais dados serão utilizados para o treinamento de um método de *Machine Learning*. Após o treinamento, o método gerará um modelo de *ML*. Tal método permite que um o utilizador do algoritmo possa fornecer uma nova imagem e receber do modelo o parâmetro ideal para o algoritmo de restauração de imagens.

O processo descrito anteriormente pode ser definido através do fluxograma descrito na Figura 6.

Com a metodologia definida para a criação do banco de dados possuindo as imagens e seus parâmetros ideais, resta como objetivo para a presente pesquisa discutir a escolha do algoritmo de *Machine Learning* a ser utilizado. Como o banco de dados ainda está por ser devidamente criado, os pesquisadores ainda não possuem os dados para aplicar e testar uma das inúmeras soluções algorítmicas disponíveis através da biblioteca *Tensorflow*. Mas estuda-se o possível uso de técnicas como Redes Neurais Convolucionais (CNN – *Convolutional Neural Network*) que possuem um bom histórico, segundo a bibliografia, quando usadas em processamento de imagens (KRIZHEVSKY, 2012; HE, 2015). Outras técnicas de regressão podem ser consideradas, com a regressão sendo definida como quando uma informação é dada ao modelo treinado e o mesmo retorna um parâmetro considerado ideal para a mesma.

Contudo, não há como definir qual técnica ou algoritmo obterá um melhor resultado em um problema de otimização sem antes testar as diferentes abordagens (WOLPERT & MACREADY, 1997), visto que cada problema tende a ter suas próprias características. Atualmente, há diferentes técnicas de *Machine Learning* (*Random Forests*, *Neural Networks*, *Support-Vector-Machines*, são alguns exemplos), algumas serão testadas para gerar resultados mais eficientes dentro do período de tempo da presente pesquisa.



**Figura 6: Fluxograma de funcionamento da solução a ser implementada.**

## CONCLUSÕES

Através do presente estudo, pode-se observar uma característica a ser determinada com o uso de *Machine Learning* nos algoritmos de tratamento de imagens. Pretende-se implementar a proposta descrita anteriormente. Esta consiste em gerar os melhores parâmetros para um banco de imagens e treinar um modelo de *Machine Learning* com o algoritmo disponível na biblioteca *Tensorflow* que ofereça a melhor relação qualidade da restauração e desempenho, essas atividades serão realizadas no decorrer da pesquisa. A paralelização de cada passo do processo da plataforma seria algo interessante para a proposta, visto que o processamento de diversas imagens terá um custo alto, se executado de forma sequencial.

Vale também ressaltar que a presente pesquisa pretende fazer com que a solução possa ser aplicada de forma fácil por outros pesquisadores. Assim, a metodologia apresentada pode ser usada e testada em filtros de ruídos que aceitam parâmetros que ainda não foram determinados de forma automática.



## REFERÊNCIAS BIBLIOGRÁFICAS

BERTERO, Mario; BOCCACCI, Patrizia. *Introduction to inverse problems in imaging*. CRC press (1998).

BRAGA, José Renato Garcia: *Navegação autônoma de VANT por imagens LIDAR*. Tese de Doutorado, Computação Aplicada – INPE, São José dos Campos (2018).

CONTE, Gianpaolo; DOHERTY, Patrick. An integrated UAV navigation system based on aerial image matching. *IEEE - AEROSPACE Conference*, [S.l.: s.n.], p. 1–10 (2008).

DONOHO, D. L., JOHNSTONE, I. M.: Ideal spatial adaptation via wavelet shrinkage. *Biometrika*, 81, 425–455 (1994).

GÉRON, A.: *Hands-On Machine Learning with Scikit-Learn & Tensorflow*. O’ReillyMedia Inc. (2017).

GOLTZ, GAM; SHIGUEMORI, E. H.; CAMPOS VELHO, H. F.: Position estimation of uav by image processing with neural networks. *X Congresso Brasileiro de Inteligência Computacional (CBIC)*, p. 1–6 (2011).

HE, Kaiming et al. Deep Residual Learning for Image Recognition. Em: arXiv:1512.03385v1 (2015)

HUYNH-THU, Q; GHANBARI, M.: Scope of validity of PSNR in image/video quality assessment. *Electron. Lett.*, 44(13), 800–801 (2008).

KIEFER, J; WOLFOWITZ, J. Stochastic Estimation of the Maximum of a Regression Function. *Ann. Math. Statist.*, 23(3), 462–466 (1952).

KRIZHEVSKY, Alex; SUTSKEVER, Ilya; HINTON, Geoffrey E. ImageNet Classification with Deep Convolutional Neural Networks Em: *NIPS* (2012)

KOZAKEVICIUS, Alice de Jesus; BAYER, Fábio Mariano. Filtragem de sinais via limiarização de coeficientes wavelet. *Ciência e Natura*, 36 - Ed. Especial, 37–51 (2014).

MORGAN, P.: *Machine Learning Is Changing the Rules*. O’Reilly Media Inc. (2018).

ROBBINS, Herbert; MONRO, Sutton. A Stochastic Approximation Method. *The Annals of Mathematical Statistics*, 22(3), 400–407 (1951).

RUDER, Sebastian. An overview of gradient descent optimization algorithms. Em: arXiv:1609.04747 (2016)

RUSSAKOVSKY, Olga et al. ImageNet Large Scale Visual Recognition Challenge. Em: arXiv:1409.0575v3 (2015)

SCHMIDT, Uwe; ROTH, Stefan. Shrinkage Fields for Effective Image Restoration. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (2014).

WOLPERT, David H.; MACREADY, William G. No Free Lunch Theorems for Optimization. Em: *IEEE TRANSACTIONS ON EVOLUTIONARY COMPUTATION*, VOL. 1, NO. 1 (1997)