

# Reconhecimento de discos abrasivos

Guilherme Rocha Gonçalves<sup>1</sup>

Universidade de São Paulo  
São Carlos, Brasil

## 1 Introdução

### 1.1 Contextualização

Último projeto sobre Redes Neurais Artificiais desenvolvida durante o curso da disciplina SEL5712 Redes Neurais Artificiais, oferecida no primeiro semestre do ano de 2019 para os alunos do programa de mestrado em Engenharia Elétrica e oferecido pelo Professor Dr. Ivan Nunes da Silva.

### 1.2 Objetivo

O objetivo deste trabalho é a identificação de tipos de discos abrasivos. Foram selecionados 5 discos da *Norton Abrasivos* para constituírem a base de dados de treinamento. Foi utilizada a rede *Inception V3*, uma versão um pouco mais elaborada da rede de aprendizagem profunda *GoogLeNet*. A rede será treinada através de uma técnica chamada *Transferência de Aprendizado*, retraindo parte da rede (que é pré-treinada) usando o *dataset* de discos abrasivos.

### 1.3 Trabalhos relacionados

O uso da rede Inception já foi feito para diversas áreas. Alguns autores aplicaram essa rede para identificar flores, numa estratégia conjunta com o uso de segmentação de imagem [5], onde foram obtidos resultados tão altos quanto 98.5% para a estratégia conjunta de FCN-CNN com foco. A estratégia proposta por Hiary et al. funcionou extremamente bem para os datasets de treino em relação às demais topologias de redes. Ainda nesse trabalho, a rede Inception teve 95% e 94% de acurácia para cada um dos datasets usados.

Outros trabalhos também aplicaram a Inception e obtiveram cerca de 95% de acurácia, como é o caso do trabalho de Bankar e Gavai [6].

## 2 Fundamentação teórica

### 2.1 GoogLeNet

A Aprendizagem Profunda (*Deep Learning*) é um ramo de aprendizado de máquina que se baseia em algoritmos que modelam abstrações e fazem o uso de múltiplas camadas para aprender com os dados. Ela pode ser tanto supervisionada como também não supervisionada. Esse tipo de método tem se tornado cada vez mais importante nas aplicações em engenharia.

As redes que usam essa tecnologia costumam ser baseadas em redes neurais artificiais, como por exemplo as Redes Neurais Convolucionais (CNNs). Com a aprendizagem profunda, cada nível de aprendizado transforma os dados de entrada em dados mais abstratos e complexos. Neste trabalho foram usadas imagens como entradas, nesse caso, cada imagem é uma matriz de *pixels*.

A rede *Inception* é derivada na rede usada como submissão no ImageNet Large Scale Visual Recognition Competition, em 2014 (ILSVRC2014). O *GoogLeNet* foi a primeira encarnação da arquitetura Inception [7] e obteve desempenho superior se comparado aos seus predecessores [4].

A competição ILSVRC é uma competição com o objetivo de traçar delimitações em volta de objetos em imagens entre 200 categorias. Os objetos detectados devem ter no mínimo 50% de correlação com a real classe para que sejam considerados como uma predição correta.

A rede Inception foi treinada pelo Google para 100000 imagens entre 1000 categorias para a competição. O treinamento foi feito usando o *DistBelief* [1] (uma versão anterior ao que se transformou no TensorFlow, em 2017) usando o Gradiente Descendente Estocástico com 0.9 de momento e uma rotina fixa de taxa de aprendizado.

Porém, este trabalho não irá treinar a rede da mesma maneira que foi criada, por falta de um *hardware* que suporte o alto custo computacional.

## 2.2 Transferência de aprendizado

Em aprendizado de máquina, transferência de aprendizado é um processo de treinamento que foca em aplicar o conhecimento adquirido por uma rede em um dado treinamento para outro subconjunto de dados, sem a necessidade de retreinar a rede inteira.

Na rede Inception, o treinamento é feito na camada superior, responsável pela classificação das imagens. Isso é feito usando o algoritmo de *backpropagation* e a função de custo da entropia cruzada para ajustar os pesos, que são ajustados de acordo com o erro entre a saída da camada *softmax* e o vetor categórico da amostra [6].

Foram usadas 361 imagens para treinar 5 categorias, que são:

- Disco de *Fibra* - 36;
- Disco *Classic* - BDA600;
- Disco de corte - BNA 12;
- Disco de *flap* - 40;
- Disco *flap Vortex* - Grosso e Muito Fino.

As 361 fotos estão distribuídas entre as 5 categorias, se tratando de fotos de vários ângulos (tanto a face superior como a face inferior dos discos) com boa iluminação e sem outros elementos de fundo, como mãos ou outros objetos. A figura 1 mostra em detalhes os discos usados para a transferência de aprendizado.

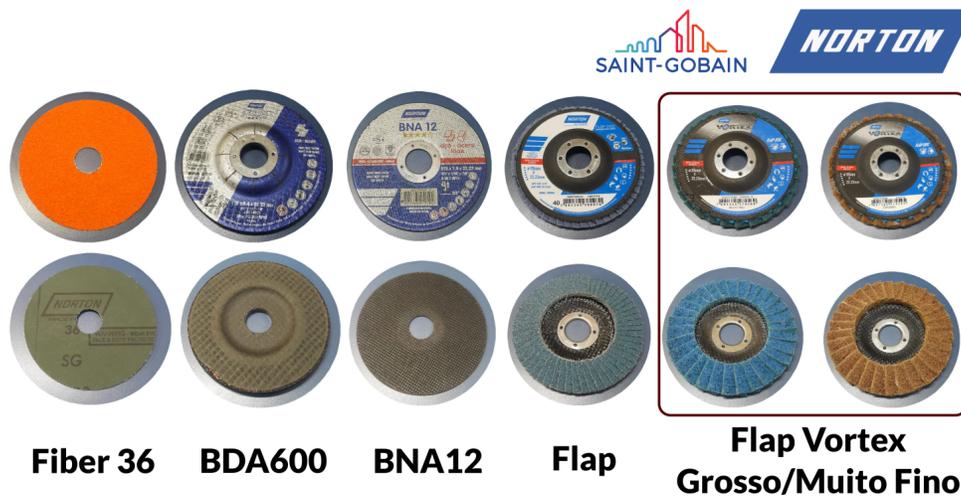


Figura 1: Tipos de discos

### 3 Materiais e Métodos

#### 3.1 Problema

Este trabalho propõe uma solução classificatória para diferenciar discos abrasivos entre um subconjunto de 5 tipos. Esse tipo de solução pode ser utilizada em uma fábrica para direcionar discos em uma linha de produção, dependendo do tipo. Essa aplicação do classificador pode ser aplicada para outros intuitos, como por exemplo a identificação de defeitos de fabricação em discos ou então para facilitar o estoque de discos. Para cada uma das aplicações, um subconjunto de treinamento que retrata muito bem o problema proposto deve ser elaborado (fotos de discos com problemas e discos em bom estado, no caso de identificação de defeitos).

#### 3.2 Bases de treino e de teste

A base de treino e teste para esta rede neural foi elaborada pelo autor e pode ser encontrada na página do GitHub [2].

É importante notar que os discos de flap do tipo "normal" e o Vortex possuem a parte superior bastante similares. De maneira análoga, os discos de Fibra 36, o BDA600 e o BNA12 também possuem a parte inferior um bastante semelhantes. Isso é importante pois pode confundir a rede neural, dependendo da quantidade de dados para treinamento.

#### 3.3 Linguagem

Os códigos deste trabalho foram feitos usando *python*. Foi utilizada a rede pré-treinada Inception v3 disponibilizada em código aberto em [3] O código está no Apêndice e também pode ser acessado através do link <https://github.com/grgoncal/SEL5712—Redes-Neurais-Artificiais>.

## 4 Resultados e discussão

#### 4.1 Classes

A rede foi retreinada usando o *database* de imagens dos discos. O parâmetro de número de épocas de treinamento foi variado em 5 valores: 200, 500, 1000, 2000 e 5000. Os resultados dos primeiros treinamentos usando uma foto de cada disco em um fundo padrão azul estão na Tabela 1.

Nº de Treinamentos	Cut Off		BDA600		Fibra - 36		Vortex Grosso		Vortex Fino		Flap	
	Top	Bottom	Top	Bottom	Top	Bottom	Top	Bottom	Top	Bottom	Top	Bottom
200	77.45	81.53	51.47	67.54	-	88.06	60.56	54.62	44.61	-	43.69	71.45
500	86.38	90.54	65.13	79.72	45.16	94.08	65.20	52.29	46.35	-	51.76	84.69
1000	91.95	95.01	72.16	84.56	46.83	96.63	70.35	54.71	50.65	-	53.13	90.33
2000	95.03	96.95	80.14	89.85	52.68	98.09	72.04	56.95	51.10	-	57.07	93.89
5000	97.29	98.59	86.53	93.35	59.20	99.14	74.66	57.05	52.68	-	61.07	97.00

Tabela 1: Variação de épocas de treinamento

Os valores da tabela estão em valores percentuais e são calculados em relação às outras categorias: se uma imagem foi classificada com 50%, isso significa que as outras categorias carregam os outros 50% de maneira distribuída, do mais provável para o menos.

Nota-se claramente que as porcentagens de precisão aumentam conforme o número de treinamentos também aumenta.

Alguns comportamentos da rede merecem uma atenção detalhada. O principal deles foi a previsão errônea da rede para a face inferior do disco Vortex Fino. Isso aconteceu devido a sua grande semelhança ao disco de Flap, conforme a Figura 3. Esse erro não aconteceu no caso do Vortex Grosso devido a sua coloração marrom.

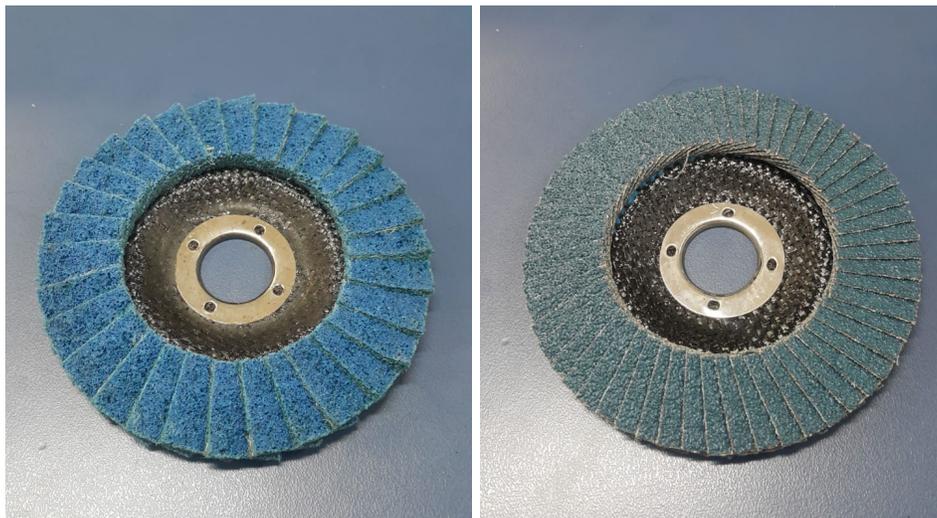


Figura 2: Comparação entre Vortex Fino e Flap

Esse tipo de erro mostra justamente que a base da rede Inception deve representar muito bem a categoria em questão, caso contrário erros como este estarão sujeitos a acontecer.

Um segundo comportamento que deve ser considerado é a baixa porcentagem de acerto para a face superior do disco de Fibra 36. De maneira parecida com o primeiro erro, a face superior do disco de Fibra é um pouco parecida com as faces inferiores dos discos de Corte (BNA12) e de desbaste (BDA600), como mostra a Figura ??.

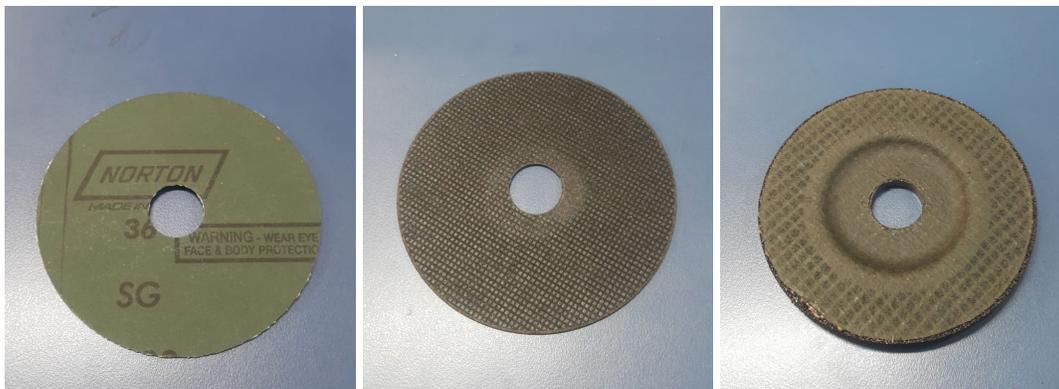


Figura 3: Comparação entre Vortex Fino e Flap

O exato mesmo comportamento é observado para as faces superiores dos discos de Flap e o Vortex Fino, mostrando que as duas categorias devem levar outros atributos (ou até mesmo uma outra topologia) para que haja uma coerência no discernimento entre si.

## 4.2 Treinamento

O maior treinamento foi plotado usando o TensorBoard, que permite acompanhar algumas informações sobre o atual treinamento da rede. A Figura 4 a seguir contém informações sobre a acurácia da rede ao decorrer das épocas de treinamento. As curvas em laranja são informações em relação ao conjunto de dados de treinamento e as em azul carregam informações sobre um conjunto de validação, que é constituído usando a técnica *random sampling*, onde objetos aleatórios de um conjunto de dados são selecionados para fazer parte de um subconjunto de teste.

Depois de 500 épocas a rede é capaz de acertar com 100% de certeza qual a categoria do próprio conjunto de treinamento, e após cerca de 3500 épocas, a rede acertou 100% os conjuntos criados pelo *random sampling*, mostrando que a rede já é aplicável.

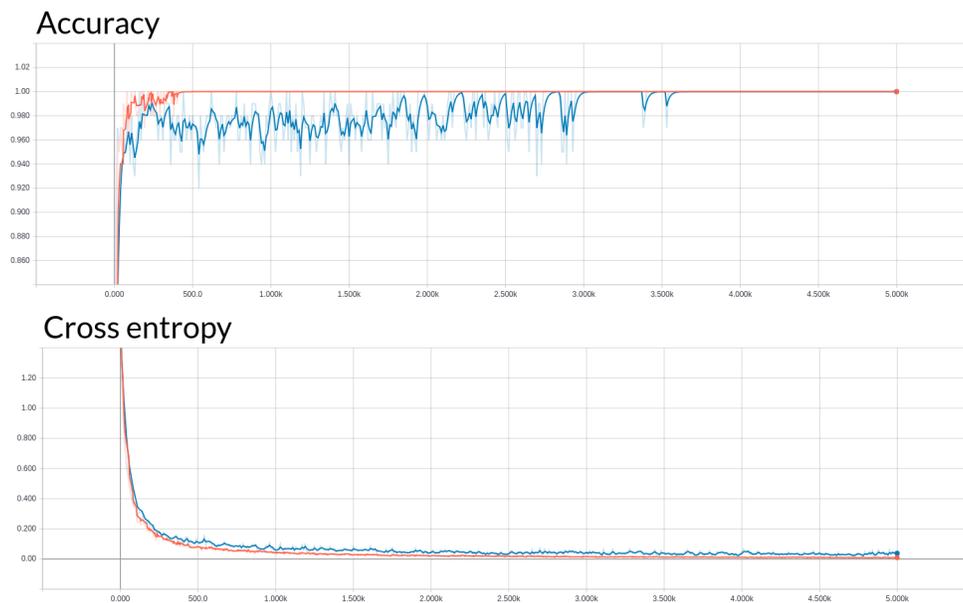


Figura 4: Comparação entre Vortex Fino e Flap

O segundo gráfico da Figura 4 mostra uma função de perda que tem como objetivo mostrar como está o processo de aprendizado da rede e observa-se que a rede retém muito bem o aprendizado ao longo das épocas.

## 5 Conclusão

O uso da rede neural baseada no modelo da Inception-v3 da plataforma TensorFlow foi usada neste trabalho e conseguiu acurácias extremamente altas para alguns casos de teste (por exemplo no caso do disco de Fibra 12, que obteve 99% de acurácia).

Este trabalho também revela alguns problemas e detalhes no funcionamento da rede. O repositório de conhecimento da rede Inception é extremamente vasto em termos de quantidade e diversidade

de categorias, o que é de grande valia para classificação de objetos com formas, cores e tamanhos variados, porém é um problema para objetos bastante similares em termos de cor e forma. Isso foi visto principalmente nos discos Flap e Vortex, chegando ao caso extremo de erro, no caso do Vortex Fino.

Ao mesmo tempo, o erro da rede também pode estar relacionado ao mal uso da rede para este problema em específico, ou também, a um conjunto de teste não muito representativo para uma certa categoria. No primeiro caso, deve-se conhecer muito bem o problema para se determinar condições de contorno para o caso de discos extramamente similares, além disso, é possível que esse modelo de rede não seja o mais adequado para a aplicação em questão. No segundo caso, seria completamente válido ampliar a base de dados de teste do disco em questão, causando um aumento na acurácia da rede.

O número de treinamentos da rede tem grande influência na acurácia da rede, ao mesmo tempo que atinge um limite de melhoramento próximo a época 4000. Números ainda maiores de épocas podem levar a problemas de *overfitting*.

Finalmente, a rede se mostrou suficiente para classificar os discos, dada as condições de contorno. Este trabalho pode ser uma porta de entrada para outros estudos sobre o tema.

## 6 Apêndice

### 6.1 Código fonte

O código fonte dos algoritmos desenvolvidos está disponível no repositório público <https://github.com/grgoncal/SEL5712—Redes-Neurais-Artificiais> para livre acesso.

## Referências Bibliográficas

- [1] Dean, J., Corrado, G., Monga, R., Chen, K., Devin, M., Mao, M., Senior, A., Tucker, P., Yang, K., Le, Q.V., et al.: Large scale distributed deep networks pp. 1223–1231 (2012)
- [2] Gonçalves, G.R.: Github: Sel5712 - redes neurais artificiais. [github.com/grgoncal/SEL5712](https://github.com/grgoncal/SEL5712)—Redes-Neurais-Artificiais, acesso em: 2019-06-17
- [3] Google, community: Tensorflow. <https://github.com/tensorflow/tensorflow> (2019)
- [4] He, K., Zhang, X., Ren, S., Sun, J.: Delving deep into rectifiers: Surpassing human-level performance on imagenet classification pp. 1026–1034 (2015)
- [5] Hiary, H., Saadeh, H., Saadeh, M., Yaqub, M.: Flower classification using deep convolutional neural networks. *IET Computer Vision* **12**(6), 855–862 (2018)
- [6] Jy, B., Ni, G.: Convolutional neural network based inception v3 model for animal classification pp. 142–146 (2018)
- [7] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., Rabinovich, A.: Going deeper with convolutions pp. 1–9 (2015)