



## Solução de quebra-cabeças usando deep learning

Marcos Toshio Ueda\*, Josue Labaki Silva.

### Resumo

Nesse trabalho, a solução de um quebra-cabeça via deep learning foi utilizada para a compreensão das ferramentas e do ambiente de desenvolvimento de uma rede neural profunda. Para tanto, foi estudado um algoritmo proposto por Noroozi e Favaro (2016) que propõe uma arquitetura chamada context-free network (CFN).

### Palavras-chave:

deep learning, jigsaw puzzles, python

### Introdução

O objetivo deste trabalho é desenvolver um algoritmo para solução de quebra-cabeças do tipo *jigsaw puzzle* usando *deep learning* que são redes neurais profundas que não exigem interferência humana direta para serem treinadas e, dessa forma, problemas complexos que requerem o reconhecimento de características abstratas podem ser resolvidos com maior agilidade. Navegação autônoma, diagnóstico de câncer e reconhecimento facial são algumas das diversas aplicações de *deep learning*. Nesse trabalho, o desenvolvimento foi realizado em *Python* em conjunto com as bibliotecas de *deep learning Keras* e *Tensorflow*, além do processamento acelerado dos dados via *GPU/CUDA*.

### Resultados e Discussão

A rede neural profunda avaliada admite a entrada das nove partes de um quebra-cabeça em um *grid* de 3X3 peças, que são originadas de um pré-tratamento e embaralhadas aleatoriamente. O processamento dos *pixels* na etapa de treinamento tem um custo computacional alto e, por essa razão, todas as imagens são tratadas e redimensionadas a fim de otimizar o processo. Ao final da rede neural, espera-se que ela forneça a ordem em que as peças foram embaralhadas, ou seja, a solução do quebra-cabeça.

Diferente dos métodos convencionais para solução de quebra-cabeças que usam as intersecções

das peças para encontrar o encaixe correto, o *deep learning* utiliza as características das imagens, assemelhando-se ao modo de solução dos seres humanos.

Por fim, analisou-se o desempenho do algoritmo através da curva de aprendizado que mede a taxa de acertos, onde dois aspectos foram observados:

-A curva de aprendizado é não linear, ou seja, há momentos em que ela piora com o tempo, mas o importante é que, na média, a taxa de aprendizado seja positiva.

-A velocidade do aprendizado depende diretamente do banco de imagens utilizado, ou seja, para grupos de imagens mais semelhantes (carros com fundo branco, por exemplo) o aprendizado tende a ser muito mais rápido.




Figura 2: Curva de aprendizado após 7h de treinamento

### Conclusão

Neste trabalho foi reproduzido um algoritmo para solução de quebra-cabeças de imagens embaralhadas usando deep learning. Como esperado, neste esquema observou-se uma taxa de aprendizado positiva com o aumento do número de imagens de treinamento.

Observou-se ainda uma dependência entre a velocidade do treinamento e o tipo das imagens dadas no treinamento. O algoritmo é capaz de resolver um quebra-cabeça em que partes embaralhadas de uma imagem são fornecidas, e a imagem desembaralhada é dada como saída

### Agradecimentos

Agradeço Prof. Josué Labaki pelo suporte e orientação durante todo o trabalho.

A minha família e ao SAE que permitiram que esse trabalho fosse realizado.

<sup>1</sup> Noroozi M, Favaro P. Unsupervised learning of visual representations by solving jigsaw puzzles. In European Conference on Computer Vision 2016 Oct 8 (pp. 69-84). Springer, Cham

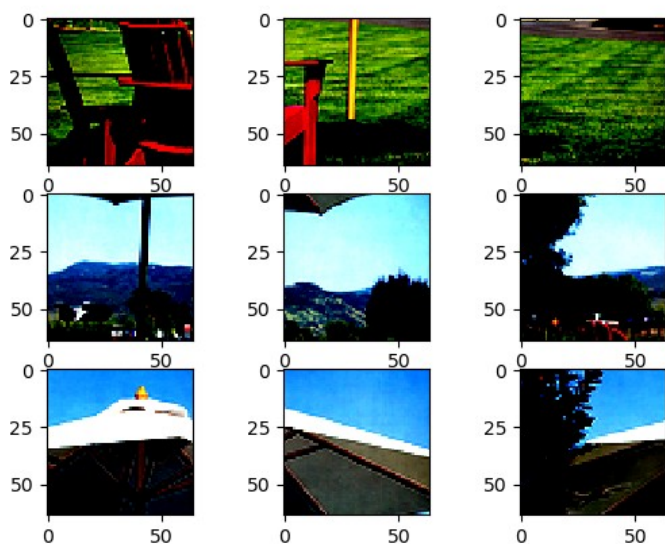


Figura 1: Exemplo de um quebra-cabeça