

# Redes Generativas Adversarias

## Aplicadas a Generación de Imágenes

F. Atenas<sup>1</sup>    F. Sanhueza<sup>1</sup>    C. Valenzuela<sup>1</sup>

<sup>1</sup>Departamento de Ingeniería Matemática  
Universidad de Chile

8 de Julio, 2017

# Problema

Nuestro trabajo consistió en el estudio del uso de redes adversariales generativas o GANs.

Estas son un modelo para generar datos de un proceso cuya densidad se encuentra implícita. Presenta ciertas ventajas respecto a otros modelos:

- ① El procedimiento para generar una muestra se hace de forma paralela.
- ② Pocos requerimientos de dimensionalidad y sobre la función  $G$  generadora.
- ③ El procedimiento es insesgado y asintóticamente consistente.
- ④ Generan muestras en un paso, a diferencia de algoritmos basados en cadenas de Markov.

# Modelo

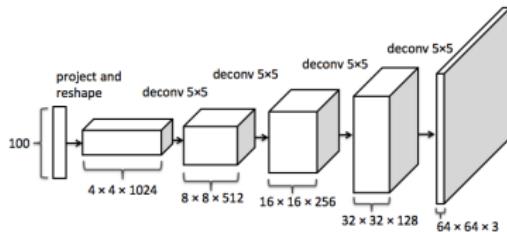
Consta de dos funciones diferenciables  $G$  y  $D$ , que son representadas por redes neuronales convolucionales.  $G$  recibe un ruido aleatorio  $z$  y a partir de él genera una muestra.  $D$  recibe una muestra y debe determinar si esta fue generada por  $G$  o si es un dato real. Así ambas participan en un juego de suma cero definido por:

$$\max_G \min_D -\mathbb{E}_{x \sim p_{\text{datos}}}(\log(D(x))) - \mathbb{E}_{z \sim p_z}(\log(1 - D(G(z))))$$

En el equilibrio de Nash de este juego resulta que  $G$  replica la distribución latente de manera perfecta.

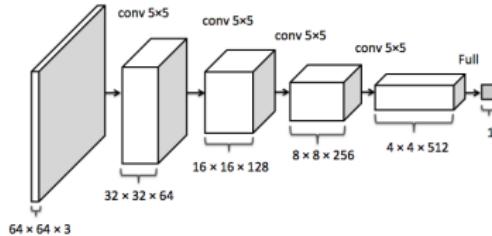
# Arquitectura

**Generador:**  
4 capas de convolución traspuesta.



Funciones de activación ReLU y de salida tanh.

**Discriminador:**  
4 capas de convolución.



Funciones de activación LReLU y salida sigmoide.

Costos:  $-\frac{1}{n} \sum_{j=1}^n (y_j \ln(\sigma(x_j)) + (1 - y_j) \ln(1 - \sigma(x_j)))$

# Resultados



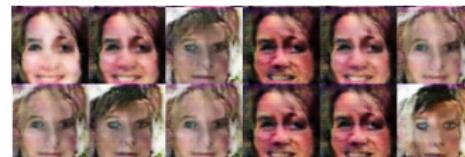
(a)  $U(-1, 1)$ , LReLU, 10 épocas.



(b)  $U(-1, 1)$ , LReLU, 20 épocas.



(c)  $\mathcal{N}(0, 1)$ , LReLU, 10 épocas.



(d)  $\mathcal{N}(0, 1)$ , LReLU, 20 épocas.



(e)  $U(-1, 1)$ , ReLU, 10 épocas.



(f)  $\mathcal{N}(0, 1)$ , ReLU, 20 épocas.

# Conclusiones

- Modelo posee una forma simple de muestreo de una distribución desconocida, sujeta a la capacidad del generador.
- Implementación flexible a modificaciones.
- El tiempo de entrenamiento está lejos del tiempo de convergencia del algoritmo.
- Generación de imágenes con atributos humanos, pero que pueden ser mejoradas para ser más realistas.
- Aún es un misterio porque las GANs prefieren generar imágenes con pocos modos diferentes.

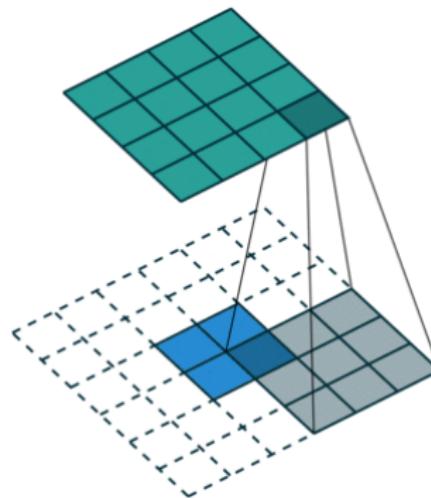
# Referencias I

- [1] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A- Courville, and Y. Bengio (2014). Generative Adversarial Nets. *arXiv preprint arXiv:1406.2661v1*.
- [2] I. Goodfellow, (2017). Generative Adversarial Networks. *arXiv preprint arXiv:1701.00160v4*.
- [3] A. Radford, L. Metz, and S. Chintala (2016). Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Network. *arXiv preprint arXiv:1511.06434v2*.
- [4] *Image Completion with Deep Learning in TensorFlow* (2017, 25 Junio). Recuperado de:  
<http://bamos.github.io/2016/08/09/deep-completion/>

## Referencias II

- [5] *Improving the way neural networks learn* (2017, 27 Junio). Recuperado de: [http://neuralnetworksanddeeplearning.com/chap3.html#the\\_cross-entropy\\_cost\\_function](http://neuralnetworksanddeeplearning.com/chap3.html#the_cross-entropy_cost_function).
- [6] Z. Liu, P. Luo, X. Wang, and X. Tang (2015). Deep Learning Face Attributes in the Wild. *Proceedings of International Conference on Computer Vision (ICCV)*.
- [7] *Convolution arithmetic tutorial* (2017, 6 Julio). Recuperado de: [http://deeplearning.net/software/theano\\_versions/dev/tutorial/conv\\_arithmetic.html#no-zero-padding-unit-strides-transposed](http://deeplearning.net/software/theano_versions/dev/tutorial/conv_arithmetic.html#no-zero-padding-unit-strides-transposed).

**Figure:** Representación Gráfica de la Convolución Traspuesta (Deconvolución). Figura obtenida de [7].



Derivada de la *sigmoid cross entropy*: Si  $\zeta = \sum_j w_j u_j + b$  es la suma con pesos de los inputs  $u$  de una capa, entonces

$$\frac{\partial C}{\partial w_j} = \frac{1}{n} \sum_u \frac{\sigma'(\zeta) u_j}{\sigma(\zeta)(1 - \sigma(\zeta))} (\sigma(\zeta) - y) = \frac{1}{n} \sum_u u_j (\sigma(\zeta) - y)$$

donde  $y$  es el label esperado (1 para imágenes reales y 0 para las falsas).