

# AI人工智慧— 藝術生成—對抗式生成網路 (GAN) &其他



stylized-neural-painting-  
oil產生這個gif


von anwendeng





課本外的主要參考來源：生成對抗網路 (GAN) ，由 Ian Goodfellow、Yoshua Bengio 和 Aaron Courville 在 2016 年的 NIPS 會議上進行的講義

[<https://arxiv.org/pdf/1701.00160.pdf>]



## NIPS 2016 Tutorial: Generative Adversarial Networks

Ian Goodfellow

OpenAI, [ian@openai.com](mailto:ian@openai.com)

### Abstract

This report summarizes the tutorial presented by the author at NIPS 2016 on *generative adversarial networks* (GANs). The tutorial describes: (1) Why generative modeling is a topic worth studying, (2) how generative models work, and how GANs compare to other generative models, (3) the details of how GANs work, (4) research frontiers in GANs, and (5) state-of-the-art image models that combine GANs with other methods. Finally, the tutorial contains three exercises for readers to complete, and the solutions to these exercises.

### Introduction

This report<sup>1</sup> summarizes the content of the NIPS 2016 tutorial on *generative adversarial networks* (GANs) (Goodfellow *et al.*, 2014b). The tutorial was designed primarily to ensure that it answered most of the questions asked by audience members ahead of time, in order to make sure that the tutorial would


01.00160v4 [cs.LG] 3 Apr 2017



# GAN

- 對抗式生成網路（Generative Adversarial Networks，簡稱GAN）是由加拿大蒙特利爾大學的Ian Goodfellow等人於2014年提出的一種深度學習模型。GAN由兩個神經網路組成：
- 生成網路（Generative Network）和
- 判別網路（Discriminative Network）。

生成網路負責生成新數據，判別網路負責判斷數據是真是假。



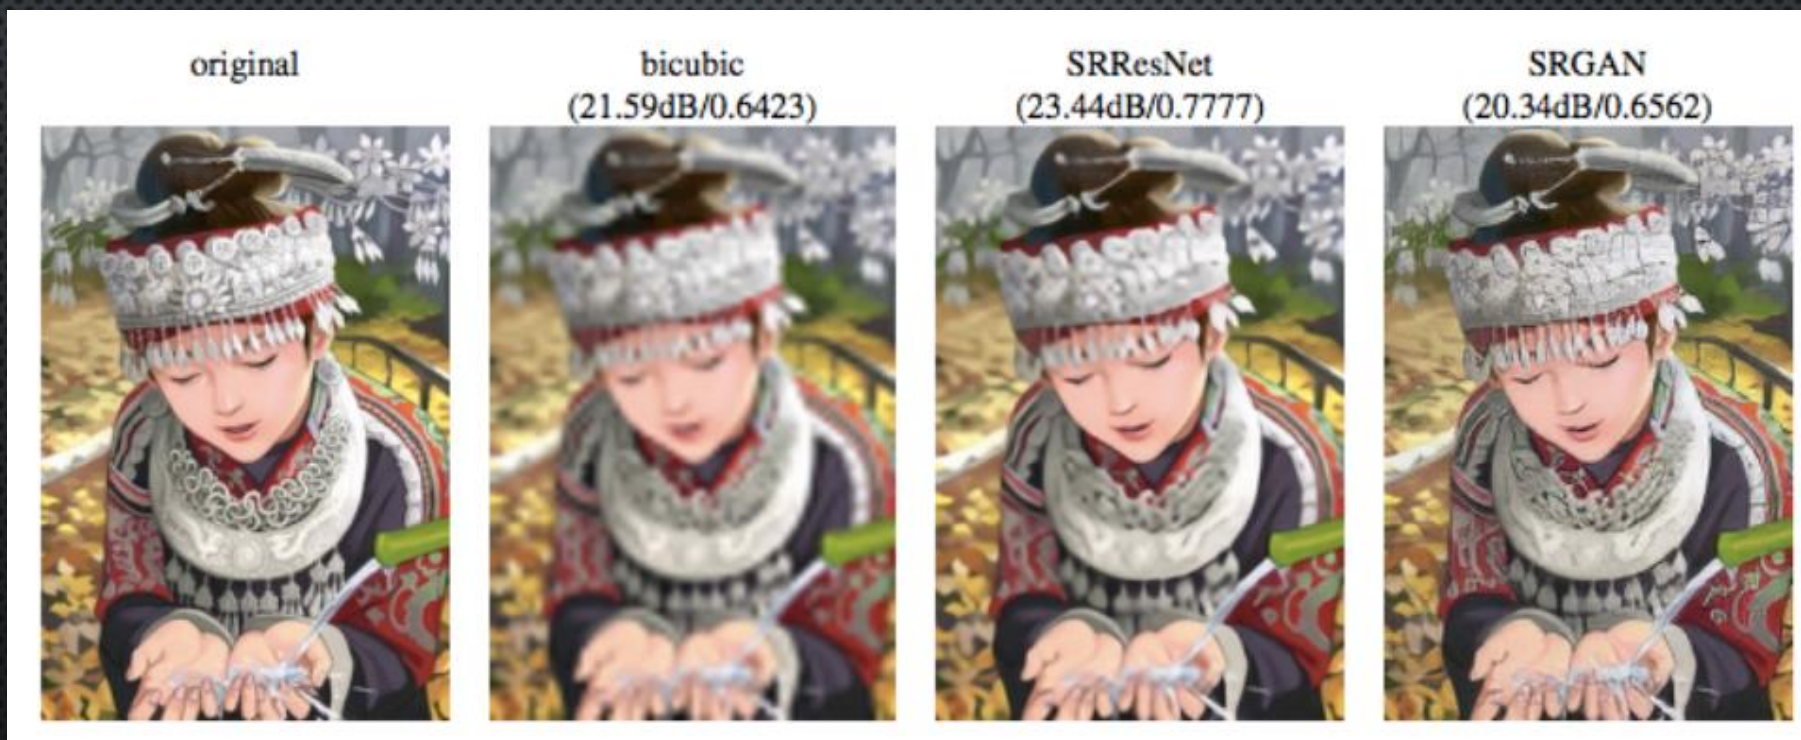


## GAN的發展可以分為以下幾個階段：

- 2014年：GAN的提出：Ian Goodfellow等人提出了GAN，並在MNIST數據集上進行了實驗。
- 2015年：GAN的發展：GAN的研究取得了快速進展，並在CIFAR-10、ImageNet等數據集上取得了良好的效果。
- 2016年：GAN的應用：GAN開始在生成圖像、音訊、文字等領域得到應用。
- 2020年至今：GAN的發展：GAN的性能得到了進一步提升，並在生成圖像、音訊、文字等領域得到了更廣泛的應用。
- GAN是一種非常強大的生成模型，它具有巨大的潛力。GAN的發展將推動深度學習在各個領域的應用。



Ledig 等人 (2016) 展示了使用生成模型訓練生成多模態分佈的逼真樣本所能取得的優異單圖超解析度結果。最左邊的圖像是原始的高解析度圖像。然後將其下採樣成低解析度圖像，並使用不同的方法嘗試恢復高解析度圖像。**bicubic**方法只是一種不使用訓練集統計資料的插值方法。**SRResNet** 是使用均方誤差訓練的神經網路。**SRGAN** 是基於 **GAN** 的神經網路，它優於 **SRResNet**，因為它能夠理解有多個正確答案，而不是將多個答案平均以強制產生單一最佳輸出。





Goodfellow, Ian; Pouget-Abadie, Jean; Mirza, Mehdi; Xu, Bing; Warde-Farley, David; Ozair, Sherjil; Courville, Aaron; Bengio, Yoshua (2014). Generative Adversarial Nets (PDF). Proceedings of the International Conference on Neural Information Processing Systems (NIPS 2014). pp. 2672–2680.

---

## Generative Adversarial Nets

---

Ian J. Goodfellow\*, Jean Pouget-Abadie†, Mehdi Mirza, Bing Xu, David Warde-Farley,  
Sherjil Ozair‡, Aaron Courville, Yoshua Bengio§

Département d'informatique et de recherche opérationnelle  
Université de Montréal  
Montréal, QC H3C 3J7

### Abstract

We propose a new framework for estimating generative models via an adversarial process, in which we simultaneously train two models: a generative model  $G$  that captures the data distribution, and a discriminative model  $D$  that estimates the probability that a sample came from the training data rather than  $G$ . The training procedure for  $G$  is to maximize the probability of  $D$  making a mistake. This

# 文章中所展示的生成圖



(a)



(b)





c)



d)

Figure 2: Visualization of samples from the model. Rightmost column shows the nearest training example of the neighboring sample, in order to demonstrate that the model has not memorized the training set. Samples are fair random draws, not cherry-picked. Unlike most other visualizations of deep generative models, these images show actual samples from the model distributions, not conditional means given samples of hidden units. Moreover, these samples are uncorrelated because the sampling process does not depend on Markov chain mixing. a) MNIST b) TFD c) CIFAR-10 (fully connected model) d) CIFAR-10 (convolutional discriminator and “deconvolutional” generator)



- 與大多數深度生成模型的視覺化不同，這些圖像顯示了模型分佈的實際樣本，而不是給定隱藏層樣本的條件平均值。此外，由於採樣過程不依賴 **Markov Chain** 混合，因此這些樣本是不相關的。
- A) MNIST
- B) TFD
- C) CIFAR-10 (全連接模型)
- D) CIFAR-10 (卷積判別器和“反捲積”生成器)




## 對抗式生成網路 (GANs) 的基本原理

- 是建立兩個玩家之間的遊戲。一個玩家是生成器G，它會生成來自與訓練資料相同分佈的樣本。另一個玩家是鑑別器D，它會檢查樣本以確定它們是真的還是假的。鑑別器使用傳統的監督式學習技術學習，將輸入分成兩類（真或假）。
- 生成器G的訓練目標是欺騙鑑別器D。我們可以將生成器想像成一個偽鈔製造者，試圖製造假鈔，而鑑別器則像警察，試圖讓真鈔通過並抓住假鈔。要想在這個遊戲中成功，偽鈔製造者必須學會製造出與真鈔無法區分的假鈔，而生成器網路必須學會生成來自與訓練資料相同分佈的樣本。



# GAN與賽局理論





# GAN 使用了非合作博弈 (non-cooperative game) 的零和遊戲 (zero-sum game)。

- 在非合作博弈中，參與者沒有任何協議或合作，每個參與者都試圖最大化自己的收益。
- 在 GAN 中，生成器 G 和判別器 D 是兩個非合作博弈者。生成器 G 的目標是生成逼真的數據，而判別器 D 的目標是區分出真實數據和生成數據。
- 生成器 G 和判別器 D 通過競爭學習，最終達到一個 Nash 均衡。在 Nash 均衡中，生成器 G 生成的數據與訓練數據相同，而判別器 D 無法區分出真實數據和生成數據。
- 因此，GAN 使用了非合作博弈的概念，將生成器 G 和判別器 D 的競爭關係建模為一個博弈。透過這個博弈，生成器 G 可以學習如何生成逼真的數據，而判別器 D 可以學習如何區分出真實數據和生成數據。
- GAN 使用的非合作博弈的具體類型是零和遊戲 (zero-sum game)。在零和博弈中，一個參與者的收益等於另一個參與者的損失。生成器 G 的收益等於判別器 D 的損失。



# 1994諾貝爾經濟學獎得主John Nash的博士論文就是`Non-Cooperative Games`

bbc.com/zhongwen/trad/world/2015/05/150524\_john\_nash\_died

2015年5月24日




曾經在1994年獲得諾貝爾經濟學獎的數學家約翰·納什與妻子在美國新澤西乘搭出租車時，出租車突然失控，夫妻兩人都在車禍中喪生。

據美國警方的消息，事發時，出租車失控後撞在防護欄上，86歲的納什和他82歲的妻子艾麗西亞死亡。

納什的生平故事曾被改編為電影《美麗的心靈》。


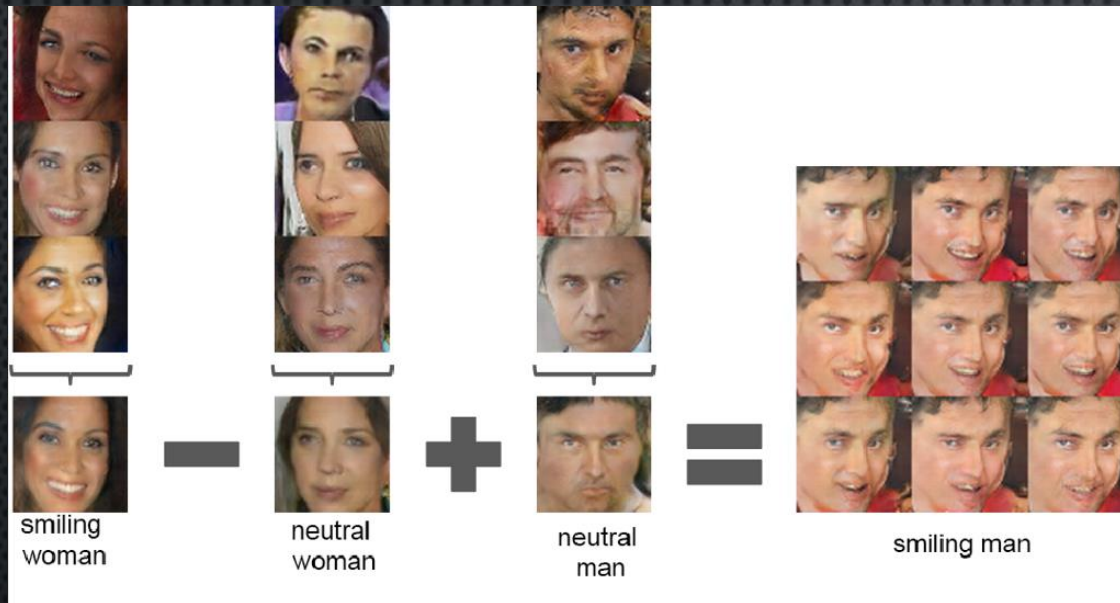


DCGAN 證明 GAN 可以學習一個分散式的表示，將性別的概念與戴眼鏡的概念分開。如果我們從有眼鏡的男人的概念表示開始，然後減去沒有眼鏡的男人的概念表示，最後加上沒有眼鏡的女人的概念表示，我們就得到了戴眼鏡的女人的概念表示。生成模型可以正確地將所有這些表示向量解碼為可以被識別為屬於正確類別的圖像。 圖片來自 Radford 等人 (2015 年) 『deep convolution GAN』






# Radford, Alec; Metz, Luke; Chintala, Soumith (2016). "Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks"





- 有 GAN 可以生成人臉圖像。讓這個 GAN 生成一個戴眼鏡的女性圖像。可以首先從一個帶眼鏡的男性概念表示開始。然後，減去一個不戴眼鏡的男性概念表示，最後加上一個不戴眼鏡的女性概念表示。這樣，我們就得到了一個帶眼鏡的女性概念表示。
- 接下來，我們可以使用生成模型將這個帶眼鏡的女性的概念表示解碼為一個圖像。生成模型會生成圖像，是一個戴眼鏡的女性。
- GAN 已經在圖像生成、文本生成、語音生成等領域得到了廣泛應用。GAN 可以生成逼真、多樣化的數據，這使得它在許多領域都很有用。

## Latent space









# 風格轉移 (style transfer) – CycleGAN

問BARD

好的，以下是 CycleGAN 的實例例圖：

馬到斑馬



馬到斑馬的 CycleGAN 轉換

這張圖像顯示了 CycleGAN 如何將馬轉換成斑馬。原始圖像是馬，生成圖像是斑馬。

貓到狗




貓到狗的 CycleGAN 轉換

這張圖像顯示了 CycleGAN 如何將貓轉換成狗。原始圖像是貓，生成圖像是狗。



# 風格轉移 (style transfer) - CycleGAN

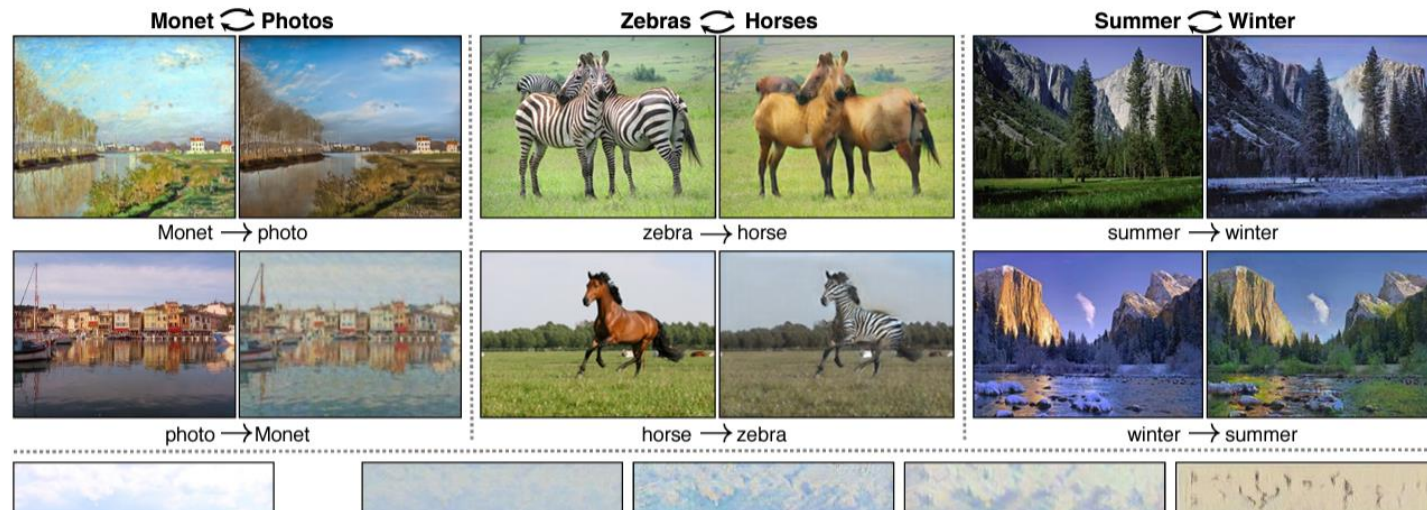




Jun-Yan Zhu\*, Taesung Park\*, Phillip Isola, and Alexei A. Efros. "Unpaired Image-to-Image Translation using Cycle-Consistent Adversarial Networks", in IEEE International Conference on Computer Vision (ICCV), 2017.  
<https://github.com/junyanz/pytorch-CycleGAN-and-pix2pix>

## Unpaired Image-to-Image Translation using Cycle-Consistent Adversarial Networks

Jun-Yan Zhu\*    Taesung Park\*    Phillip Isola    Alexei A. Efros  
Berkeley AI Research (BAIR) laboratory, UC Berkeley



CVJ 24 Aug 2020



# 玩GAN要用GPU



為什麼有人說GAN需要GPU?



有人說 GAN 需要 GPU 是因為 GAN 的訓練需要大量的計算資源。GAN 的訓練過程通常需要迭代大量的數據，每一次迭代都需要生成新的圖像，並由判別器進行判斷。這個過程需要大量的浮點運算，因此需要使用 GPU 才能進行高效的訓練。

以下是 GAN 需要 GPU 的一些具體原因：

- GAN 的訓練需要大量的數據。這些數據通常是圖像或音頻等形式的數據，需要使用 GPU 來進行快速的數據處理。
- GAN 的訓練需要大量的浮點運算。生成器和判別器都需要進行大量的矩陣運算，才能生成逼真的圖像或音頻。GPU 可以提供大量的浮點運算能力，因此可以提高 GAN 的訓練效率。
- GAN 的訓練需要大量的內存。生成器和判別器都需要存儲大量的數據，才能進行訓練。GPU 通常具有更大的內存容量，因此可以存儲更多的數據，從而提高 GAN 的訓練效率。

當然，GAN 也可以在 CPU 上進行訓練，但效率會降低。在 CPU 上訓練 GAN 可能需要數天或數周的時間，而使用 GPU 可以將訓練時間縮短到數小時或數分鐘。

以下是一些使用 GPU 訓練 GAN 的優點：

- 可以提高訓練效率，縮短訓練時間。
- 可以提高模型的性能，生成更逼真的圖像或音頻。
- 可以降低訓練成本，因為 GPU 的價格通常比 CPU 低。



# 感謝觀賞

Herzlichen Dank für die  
Aufmerksamkeit

von anwendeng