

---

# Various generative models and their analysis

---

**DMQA Open Seminar**

**2023.11.10**

**Data Mining & Quality Analytics Lab.**

**정구진**

# 발표자 소개

---



## 정구진

- 고려대학교 산업경영공학과 대학원 재학
- Data Mining & Quality Analytics Lab. (김성범 교수님)
- Ph.D. Student (2023.03 ~ Present)

## Research Interest

- Computer vision
- Generative models

## Contact

- kujhin@korea.ac.kr
-

# TABLE OF CONTENTS

## 01

### ● Overview

- Generative AI Timeline
- Based study
- Generative model

## 02

### ● ML Based

- Gaussian Mixture Models
- Hidden Markov Models
- Latent Dirichlet Allocation

## 03

### ● DL Based

- Boltzmann machines
- Variational Autoencoders
- Generative Adversarial Networks

## 04

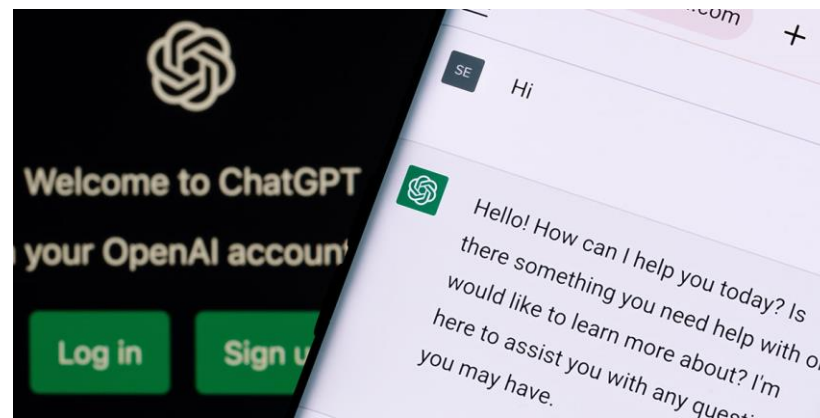
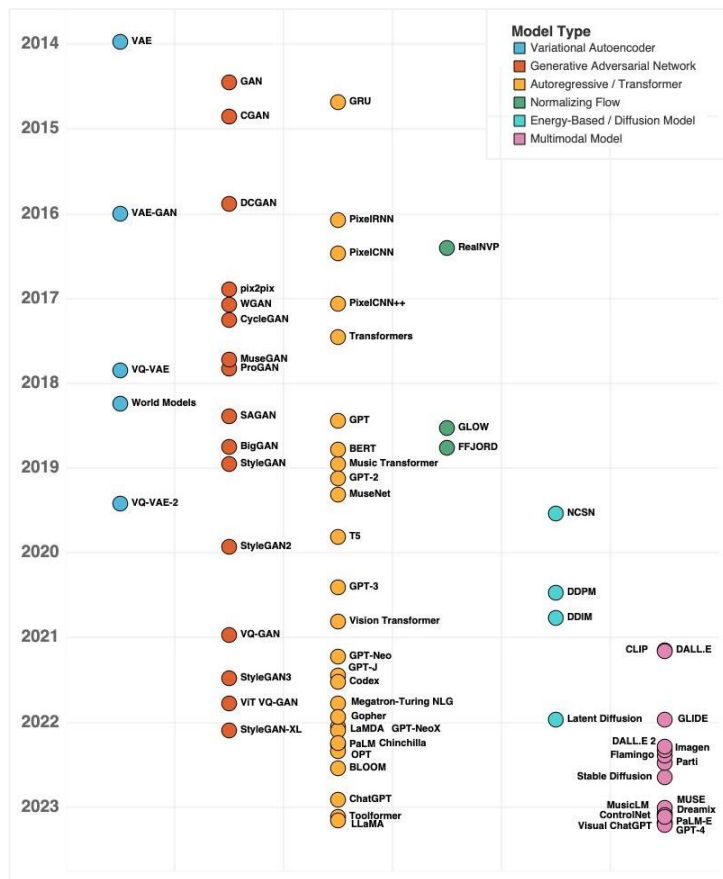
### ● Analysis & Conclusion

- Analysis
- Conclusion




Overview

# 01 Generative AI Timeline



No negative prompt




Negative prompt: windy

\*<https://www.linkedin.com/feed/update/urn:li:activity:7044233450295316480/>




# Generative AI Timeline



## 2014 – 2017 : The VAE and GAN era

- VAE는 Generative AI의 발화를 촉발시킨 불씨
- 2014년 Generative Adversarial Network(GAN)의 등장 이후 GAN 모델 아키텍처의 기본적인 변화가 주를 이룸
- GAN을 사용하여 새로운 도메인에 대응하는 연구 진행 (pix2pix 및 Cycle GAN, MuseGAN 등)



## 2018 – 2019 : The Transformer era

- Transformer는 GPT의 도입과 함께 빠르게 주목받음
- 이 후 점진적으로 더 큰 언어모델이 구축되었으며, GPT-2 (15억 parameters)와 T5(110억 parameters)가 두드러진 예시로 꼽힘

## 2020 – 2022 : The Big Model era


- 서로 다른 생성 모델링의 아이디어가 합쳐짐
- 미래의 큰 이미지 생성 모델의 기초를 마련할 DDPM과 DDIM이 소개
- GPT-3 출시 (1750억 parameters)
- 다양한 언어 모델 (딥마인드의 Gopher, Chinchilla, 구글의 LaMDA, PaLM, 메타의 OPT)
- Multimodal 트렌드로써 DALL.E2 출시
- Latent Diffusion, Stable Diffusion



# 01 Basic paper

Computer Science Review 38 (2020) 100285


---



Contents lists available at [ScienceDirect](#)

## Computer Science Review

journal homepage: [www.elsevier.com/locate/cosrev](http://www.elsevier.com/locate/cosrev)



---

## A comprehensive survey and analysis of generative models in machine learning

Harshvardhan GM\*, Mahendra Kumar Gourisaria, Manjusha Pandey, Siddharth Swarup Rautaray

*School of Computer Engineering, Kalinga Institute of Industrial Technology, Deemed to be University, Bhubaneswar, 751024, Odisha, India*

---

**ARTICLE INFO**

---

*Article history:*  
 Received 18 April 2020  
 Received in revised form 28 June 2020  
 Accepted 11 July 2020  
 Available online 30 July 2020

---

*Keywords:*  
 Generative models  
 Machine learning  
 Deep learning  
 Neural networks  
 Bayesian inference

**ABSTRACT**

---

Generative models have been in existence for many decades. In the field of machine learning, we come across many scenarios when directly learning a target is intractable through discriminative models, and in such cases the joint distribution of the target and the training data is approximated and generated. These generative models help us better represent or model a set of data by generating data in the form of Markov chains or simply employing a generative iterative process to do the same. With the recent innovation of Generative Adversarial Networks (GANs), it is now possible to make use of AI to generate pieces of art, music, etc. with a high extent of realism. In this paper, we review and analyse critically all the generative models, such as Gaussian Mixture Models (GMM), Hidden Markov Models (HMM), Deep Boltzmann Machines (DBM), Deep Boltzmann Networks (DBN), Deep Boltzmann Machines (DBM), and GANs. We study their algorithms and implement each of the models in a Python environment in which generative model to pick from while dealing with a problem. We also provide some noteworthy contributions done in the past to these models from the

"A comprehensive survey and analysis of generative models in machine learning"

Computer Science (2020)


23년 11월 9일 기준 205회 인용

© 2020 Elsevier Inc. All rights reserved.



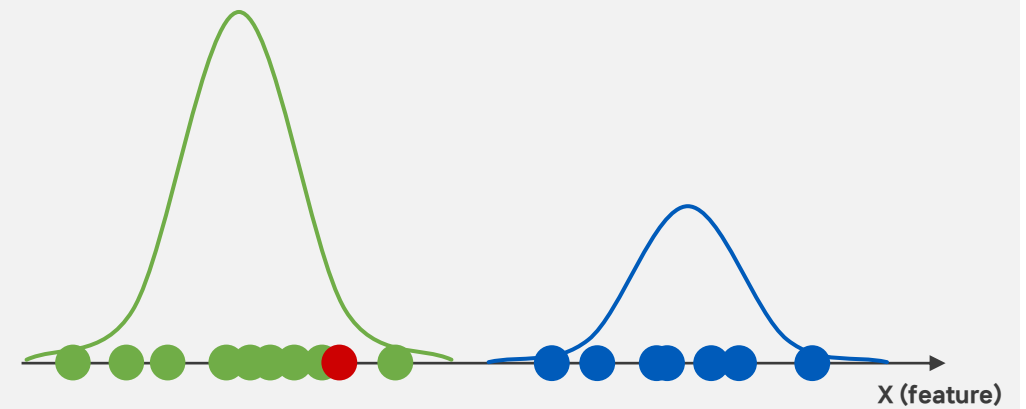
# 01 What is a generative model?

## Discriminative Model



$$p(y|x)$$

## Generative Model



$$p(x, y) = p(y) \cdot p(x|y)$$



# What is a generative model?




Fig. 2. Classification of different generative models discussed in this paper with respect to ML and DL (Machine Learning and Deep Learning).

## Today's contents

### 01

● Overview

- 생성 AI Timeline
- Based study
- Generative model

### 02

● ML Based

- Gaussian Mixture Models
- Hidden Markov Models
- Latent Dirichlet Allocation

### 03

● DL Based

- Boltzmann machines
- Variational Autoencoders
- Generative Adversarial Networks


### 04

● Analysis & Conclusion

- Analysis
- Conclusion



# 02 Gaussian Mixture Models (GMM)



## Gaussian Mixture Models

- 여러 개의 가우시안 분포를 선형 결합을 통해 생성해 낸 분포
- 가우시안 분포는 실수 값을 가지는 연속 확률 변수에 대해 평균을 중심으로 대칭인 정규 분포

## Notation


- $\mu_i$  : 평균,  $\rho_i$  : 표준편차,  $\pi_i$  : 각 가우시안 분포의 가중치
- $0 \leq \pi_i \leq 1$ , 왼쪽 그림에서  $i \in \{1, 2, 3\}$
- $\sum_{i=1}^N \pi_i = 1$
- $N(X|\mu, \Sigma)$

$$= \frac{1}{2\pi^{D/2}|\Sigma|^{1/2}} \exp\left\{-\frac{1}{2}(X - \mu)^T \Sigma^{-1}(X - \mu)\right\}$$




# 02 GMM - Covariance


$$N(X | \mu, \Sigma) = \frac{1}{2\pi^{D/2} |\Sigma|^{1/2}} \exp \left\{ -\frac{1}{2} (X - \mu)^T \Sigma^{-1} (X - \mu) \right\}$$



$$\begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$$



$$\begin{bmatrix} 2 & 0 \\ 0 & 0.6 \end{bmatrix}$$

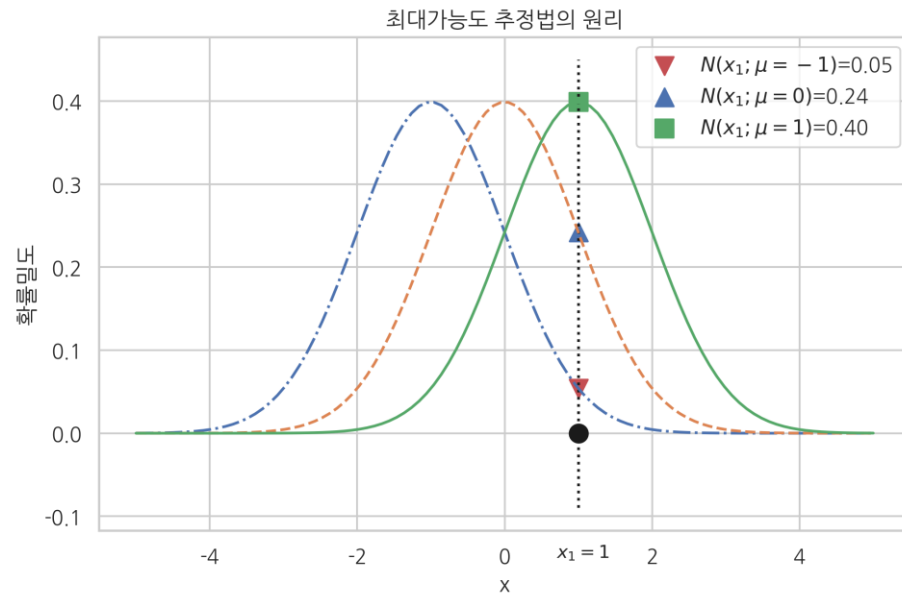


$$\begin{bmatrix} 1 & 0.8 \\ 0.8 & 1 \end{bmatrix}$$

\*<https://ratsgo.github.io/speechbook/docs/am/gmm>



# 02 GMM - Maximum Likelihood Estimation



$$(1) \quad L(\theta; x_1, \dots, x_N) = P(x_1, \dots, x_N; \theta) = \prod_{i=1}^N N(x_i | \mu, \sigma^2)$$

$$(2) \quad \log L(\theta; x_1, \dots, x_N) = \sum_{i=1}^N \log N(x_i | \mu, \sigma^2)$$

$$= -\frac{1}{2} \sum_{i=1}^N \frac{(x_i - \mu)^2}{\sigma^2} - \frac{N}{2} \log(2\pi\sigma^2)$$

$$(3) \quad \frac{\partial \log L}{\partial \mu} = \gamma \sum_{i=1}^N (x_i - \mu) = 0 \quad \rightarrow \quad \mu = \frac{1}{N} \sum_{i=1}^N x_i$$

$$(4) \quad \Sigma = \frac{1}{N} \sum_{i=1}^N (x_i - \mu)(x_i - \mu)^T$$

\*<https://ratsgo.github.io/speechbook/docs/am/gmm>




# 02 GMM - EM Algorithm

## Gaussian Mixture Model

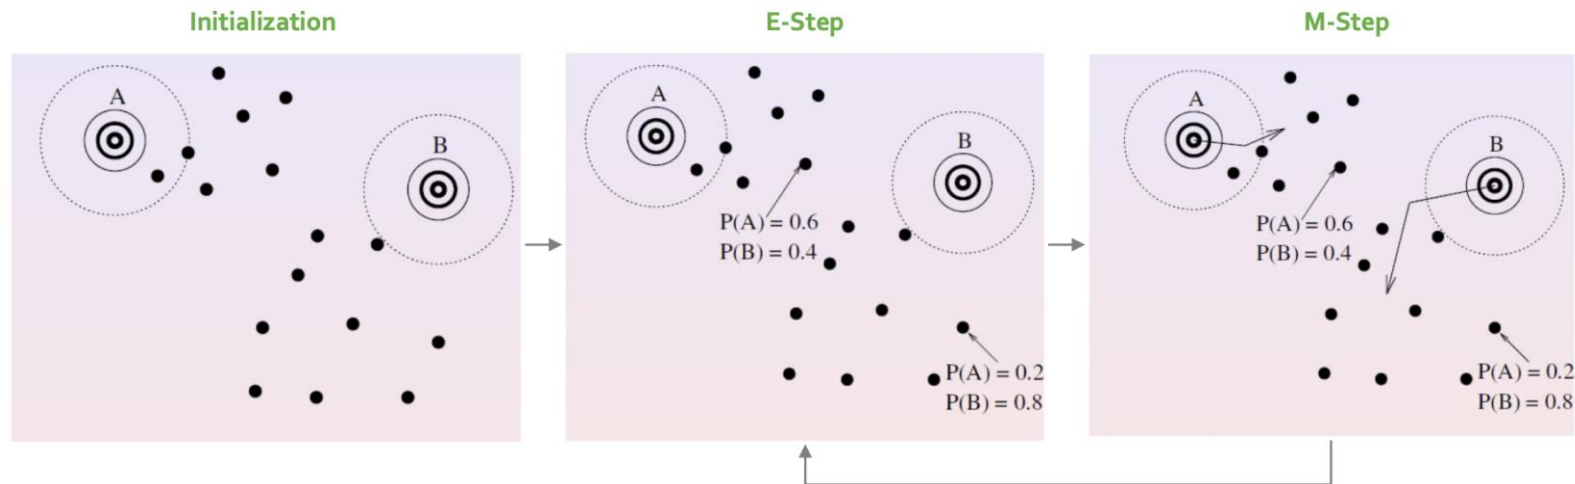
$$f(X|\lambda) = \sum_{j=1}^M \pi_j N(X|\mu_j, \Sigma_j)$$

$$\lambda = \{\pi_j, \mu_j, \Sigma_j\}, \quad j = 1, \dots, M$$

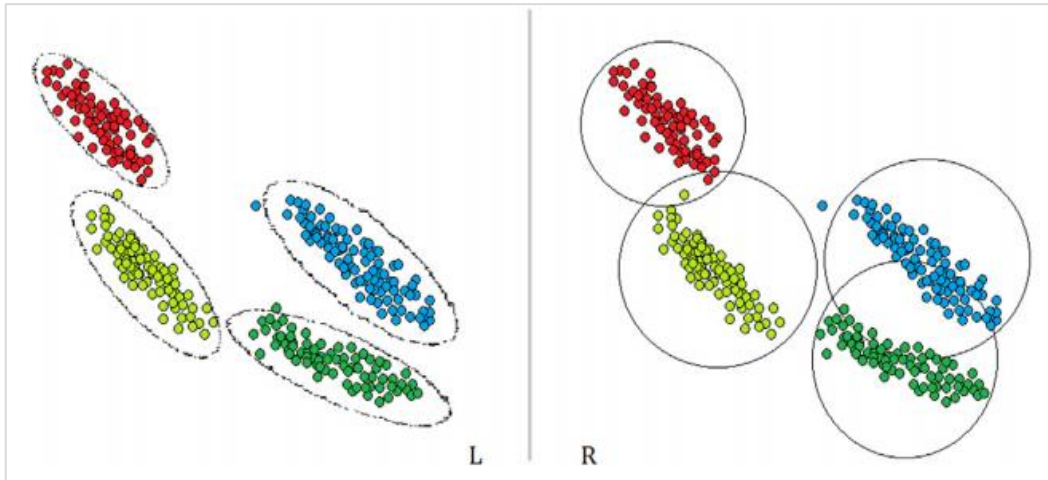


## Expectation-Maximization Algorithm

- E-Step : parameter들이 주어졌을 때, 조건부 확률을 계산
- M-Step : Likelihood를 최대화 하는 parameter로 업데이트



[\\*https://ratsgo.github.io/speechbook/docs/am/gmm](https://ratsgo.github.io/speechbook/docs/am/gmm)



- GMM은 K-means 알고리즘을 일반화 한 것으로 간주됨
- 클러스터링에도 잘 작동하지만, 밀도 추정을 위한 알고리즘이라고 부르는 것이 더 정확함
- GMM이 적용된 분포와 유사하게 분포된 새로운 데이터를 생성하는 방법을 제공 → Generative probabilistic model

## GMM이 사용되는 분야

- 언어 식별 시스템
- 음성 인식
- 악센트 인식




# Hidden Markov Models (HMM)


## Hidden Markov Model

- 통계적 markov 모델의 하나로, 시스템이 은닉된 상태와 관찰가능한 결과의 두 가지 요소로 이루어진 모델
- **Markov Property** : 과거와 현재 상태가 주어졌을 때의 **미래 상태의 조건부 확률 분포**가 과거 상태와는 무관하게 **현재 상태에 의해서만 결정**

A Markov Model



A Hidden Markov Model



### Transition probability (전이 확률)

시간  $t-1$ 에서 은닉 상태가 주어졌을 때, 시간  $t$ 에서의 은닉 상태가 선택될 확률분포

### Emission probability (방출 확률)

주어진 상태  $x(t)$ 에서 특정한 결과값  $y(t)$ 가 관측될 확률 분포

\*<https://bioinformaticsandme.tistory.com/53>



# 02 Latent Dirichlet Allocation (LDA)

Topics

gene	0.04
dna	0.02
genetic	0.01
...	

life	0.02
evolve	0.01
organism	0.01
...	

brain	0.04
neuron	0.02
nerve	0.01
...	

data	0.02
number	0.02
computer	0.01
...	

Documents

Topic proportions & assignments

### Seeking Life's Bare (Genetic) Necessities

COLD SPRING HARBOR, NEW YORK— How many genes does an organism need to survive? Last week at the genome meeting here,\* two genome researchers with radically different approaches presented complementary views of the basic genes needed for life. One research team, using computer analyses to compare known genomes, concluded that today's organisms can be sustained with just 250 genes, and that the earliest life forms required a mere 128 genes. The other researcher mapped genes in a simple parasite and estimated that for this organism, 800 genes are plenty to do the job—but that anything short of 100 wouldn't be enough. Although the numbers don't match precisely, those predictions

"are not all that far apart," especially in comparison to the 75,000 genes in the human genome, notes Siv Andersson of Uppsala University in Sweden, who arrived at the 800 number. But coming up with a consensus answer may be more than just a genetic numbers game, particularly as more and more genomes are completely mapped and sequenced. "It may be a way of organizing any newly sequenced genome," explains Arcady Mushegian, a computational molecular biologist at the National Center for Biotechnology Information (NCBI) in Bethesda, Maryland. Comparing an

**Stripping down.** Computer analysis yields an estimate of the minimum modern and ancient genomes.

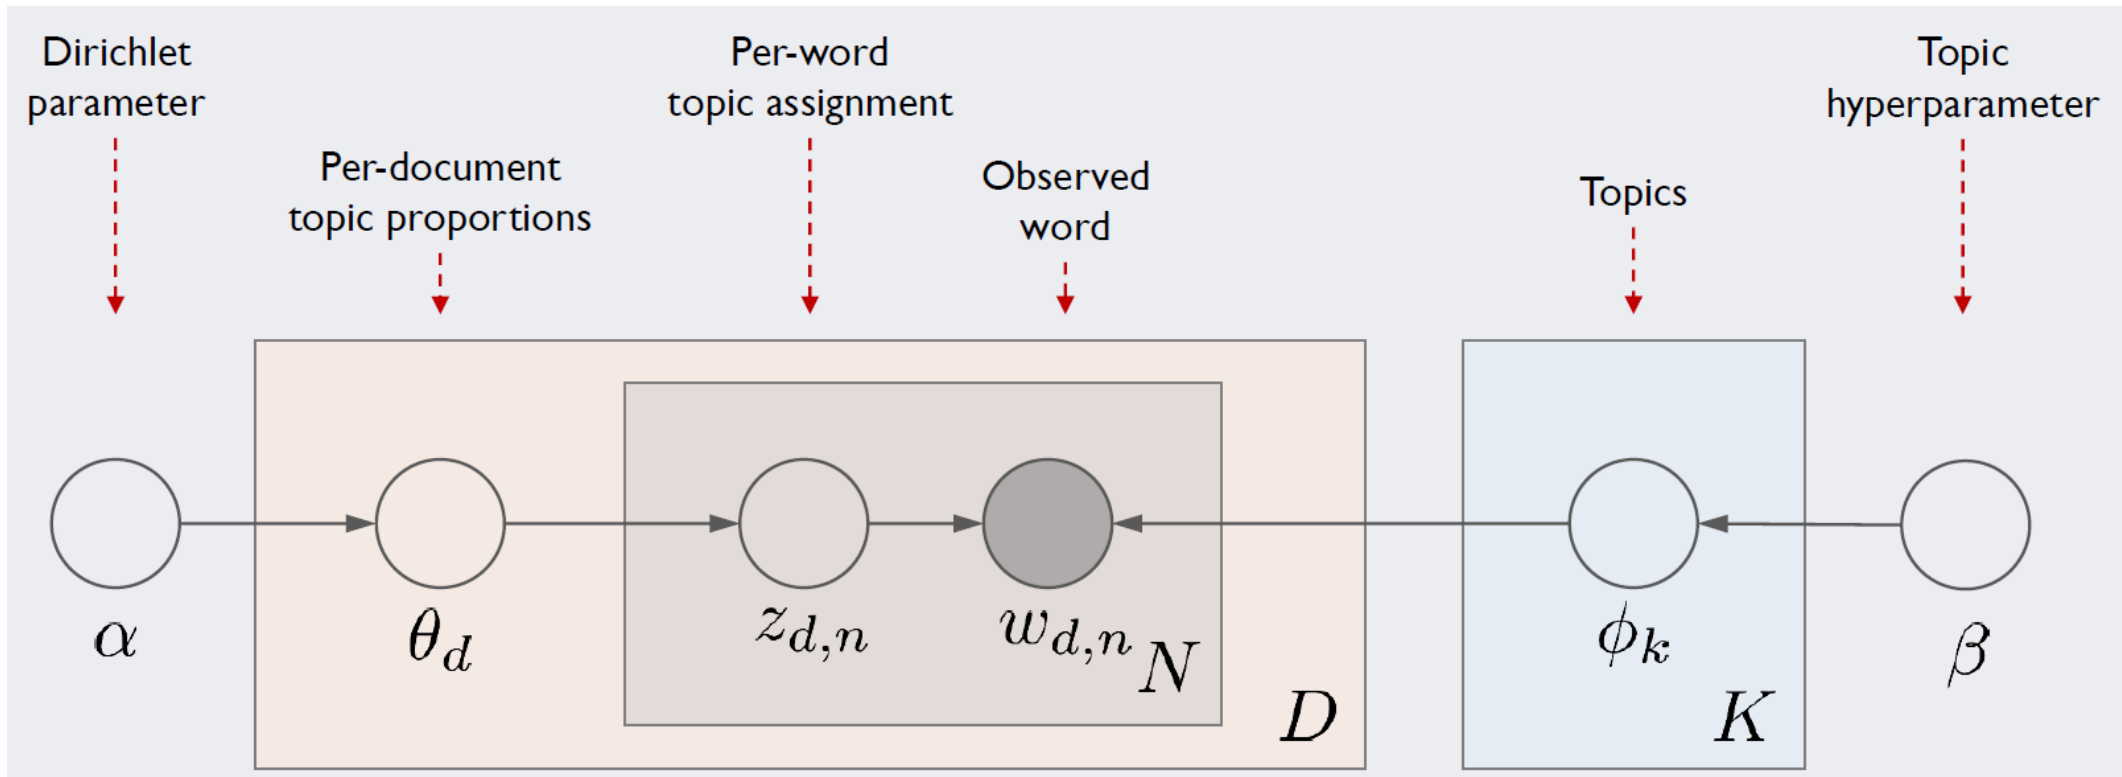
\* Genome Mapping and Sequencing, Cold Spring Harbor, New York, May 8 to 12.

SCIENCE • VOL. 272 • 24 MAY 1996





# 02 LDA architecture






# 02 LDA architecture

$$p(\phi_{1:K}, \theta_{1:D}, z_{1:K}, w_{1:K}) = \prod_{i=1}^K p(\phi_i | \beta) \prod_{d=1}^D p(\theta_d | \alpha) \left( \prod_{n=1}^N p(z_{d,n} | \theta_d) p(w_{d,n} | \phi_{1:K}, z_{d,n}) \right)$$

$\phi_{1:K}$  : 모든 토픽에서의 단어 분포  
 $\theta_{1:D}$  : 모든 문서에서 토픽의 비중  
 $z_{1:K}$  : 모든 문서에서 어떤 단어가 어느 토픽에서 왔는지  
 $w_{1:K}$  : 모든 문서에서의 단어  
 → 모든 토픽과 문서에서의 단어가 생성될 결합 확률 분포


- ### Gibbs sampling
- 마코프 체인 몬테 카를로 (MCMC) 방법의 일종으로, 복잡한 다변수 확률 분포로부터 샘플을 추출하는 데 사용
  - 다음 번 생성될 표본은 현재 샘플에 영향을 받음
  - 다만 조건부 분포에 따라 순차적으로 샘플링
  - 복잡한 확률 분포를 탐색할 수 있고, 특정 확률 변수의 기대값을 추정할 수 있음



\*<https://ratsgo.github.io/statistics/2017/05/31/gibbs/>



# 03 Boltzmann Machines (BM)



- 볼츠만 머신의 일반적인 형태는 모든 신경망 노드들이 서로 빠짐없이 연결되어 있는 **완전 그래프 구조**
- 볼츠만 머신의 neuron
  - Visible unit : 기존에 주어진 (input) 특징 데이터를 나타냄
  - Hidden unit : 추정하고자 하는 확률 분포를 나타냄

$$P(v, h) = \frac{\exp(-E(h, v))}{Z}$$



$$\text{where } Z = \sum_{h', v'} \exp(-E(h', v'))$$



\*<https://www.asimovinstitute.org/neural-network-zoo/>



# Restricted Boltzmann Machines (RBM)

Boltzmann Machine (BM)    Restricted BM (RBM)



-  Visible unit : 기존에 주어진 (input) 특징 데이터를 나타냄
-  Hidden unit : 추정하고자 하는 확률 분포를 나타냄

$$p(v, h) = \frac{e^{-E(v, h)}}{Z}$$

where  $E(v, h) = -b'v - c'h - h'Wv$

-----  
에너지의 정의

$$p(h|v) = \frac{p(h, v)}{p(v)} = \frac{1}{Z} \frac{\exp(-E(h, v))}{\sum_h p(h, v)}$$

$$p(h_i = 1|v) = \sigma(c_i + W_i v)$$

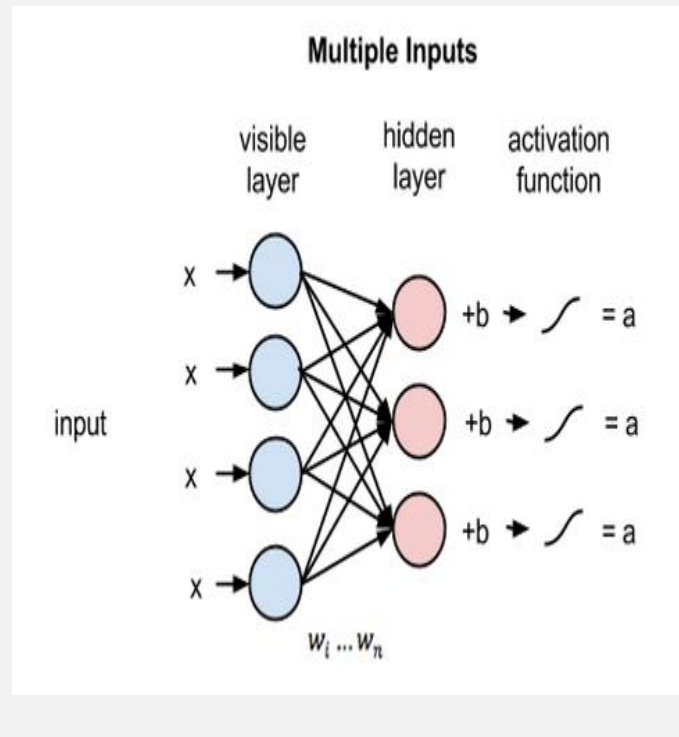
$$p(v_j = 1|h) = \sigma(b_j + W'_j h)$$

\*<https://www.asimovinstitute.org/neural-network-zoo/>

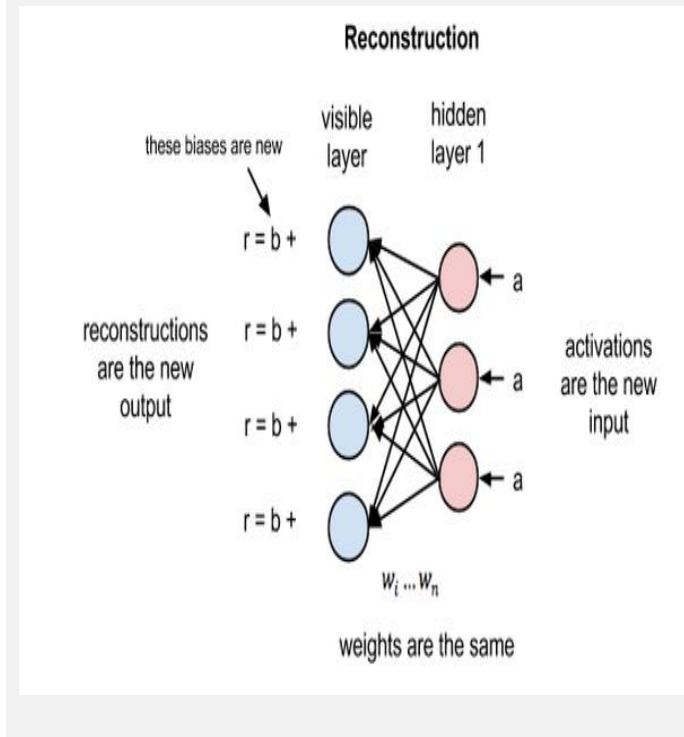


# 03 RBM - Training


## Forward



## Backward



## Update




\* <https://steemit.com/kr/@yoonheeseung/2-restricted-boltzmann-machines-rbms>


03

# Deep Belief Network (DBN)


Boltzmann Machine (BM)



Restricted BM (RBM)



Deep Belief Network (DBN)



**DBN 개념**

입력층과 은닉층으로 구성된 **RBM**을 블록처럼 여러 층으로 쌓은 형태로 연결된 신경망

**개발 배경**

Feed forward 신경망에서 신경망의 층 수가 늘어나면서 발생하는 **gradient descent vanishing** 문제 해결 필요

**주요 특징**

결과값 없이 입력 값으로만 학습 수행 → **비지도 학습**

학습 데이터가 충분하지 않을 때 유용


사전 훈련된 RBM 을 층층이 쌓아 만들

[\\*https://www.asimovinstitute.org/neural-network-zoo/](https://www.asimovinstitute.org/neural-network-zoo/)



# DBN - 특징 및 RBM과의 차이


$$P(x, h^1, \dots, h^l) = \left( \prod_{k=1}^{l-2} P(h^{k+1} | h^k) \right) P(h^1, h^2)$$



\* <https://www.analyticsvidhya.com/blog/2022/03/an-overview-of-deep-belief-network-dbn-in-deep-learning/>



# 03 Deep Boltzmann Machine (DBM)







# 03 DBM - 구조

1


- 가장 아래쪽과 v 레이어를 두 배로 늘림
- RBM의 스택을 학습

2


- $w^1$  을 고정하고  $h^1$ 을  $P(h^1|v, 2W^1)$ 로 생성
- Weights vector  $2W^2$ 를 가지는 중간 RBM 생성
- $w^2$  를 고정하고  $h^2$ 를  $P(h^2|v, 2W^2)$ 로 생성
- Weights vector  $2W^3$ 를 가지는 중간 RBM 생성

3

- 최상위 RBM의 hidden vector  $h^3$  두 배로 늘림
- $w^3$ 를 연결하고  $w^1, w^2, w^3$ 를 사용하여 DBM 구성

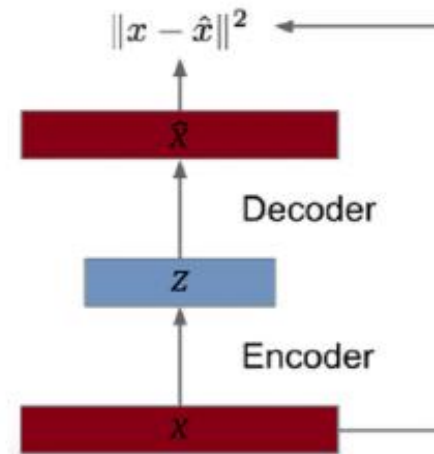



Deep Boltzmann Machine





# 03 Autoencoder

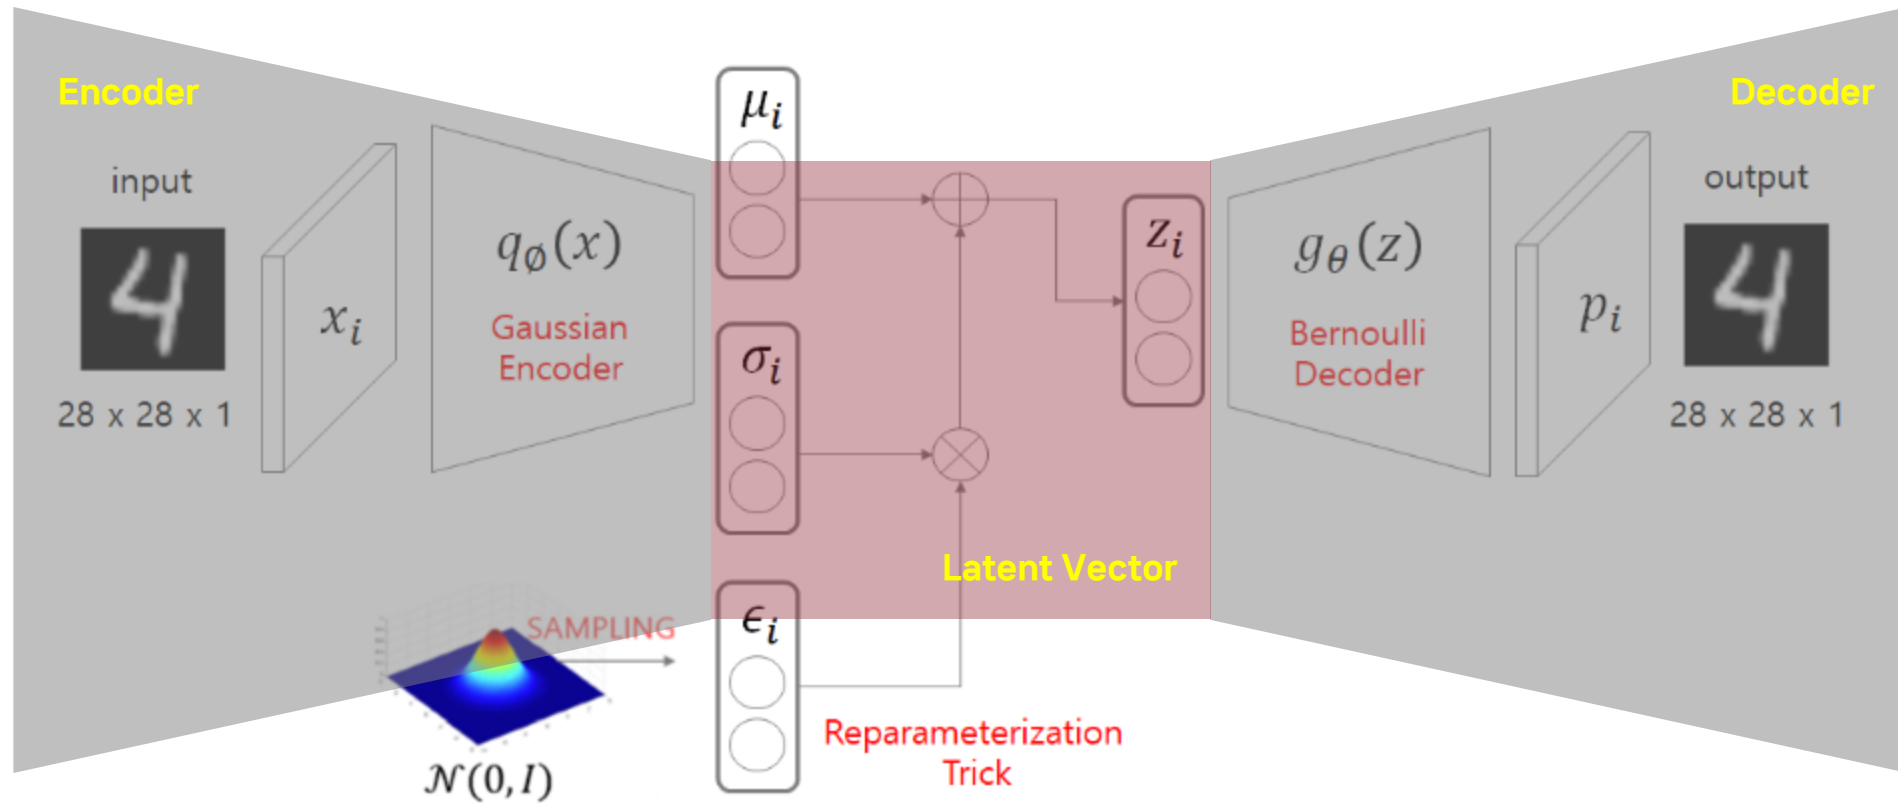


## Autoencoder

- 일반적으로 Autoencoder는 3개의 계층으로 구성
- 입력 계층인  $X$ , 입력 데이터의 정보를 압축하고 있는 Latent vector  $Z$ , 출력 계층  $\hat{X}$
- Label이 없는 데이터로부터 낮은 차원의 특성 표현을 학습하는 비지도 학습



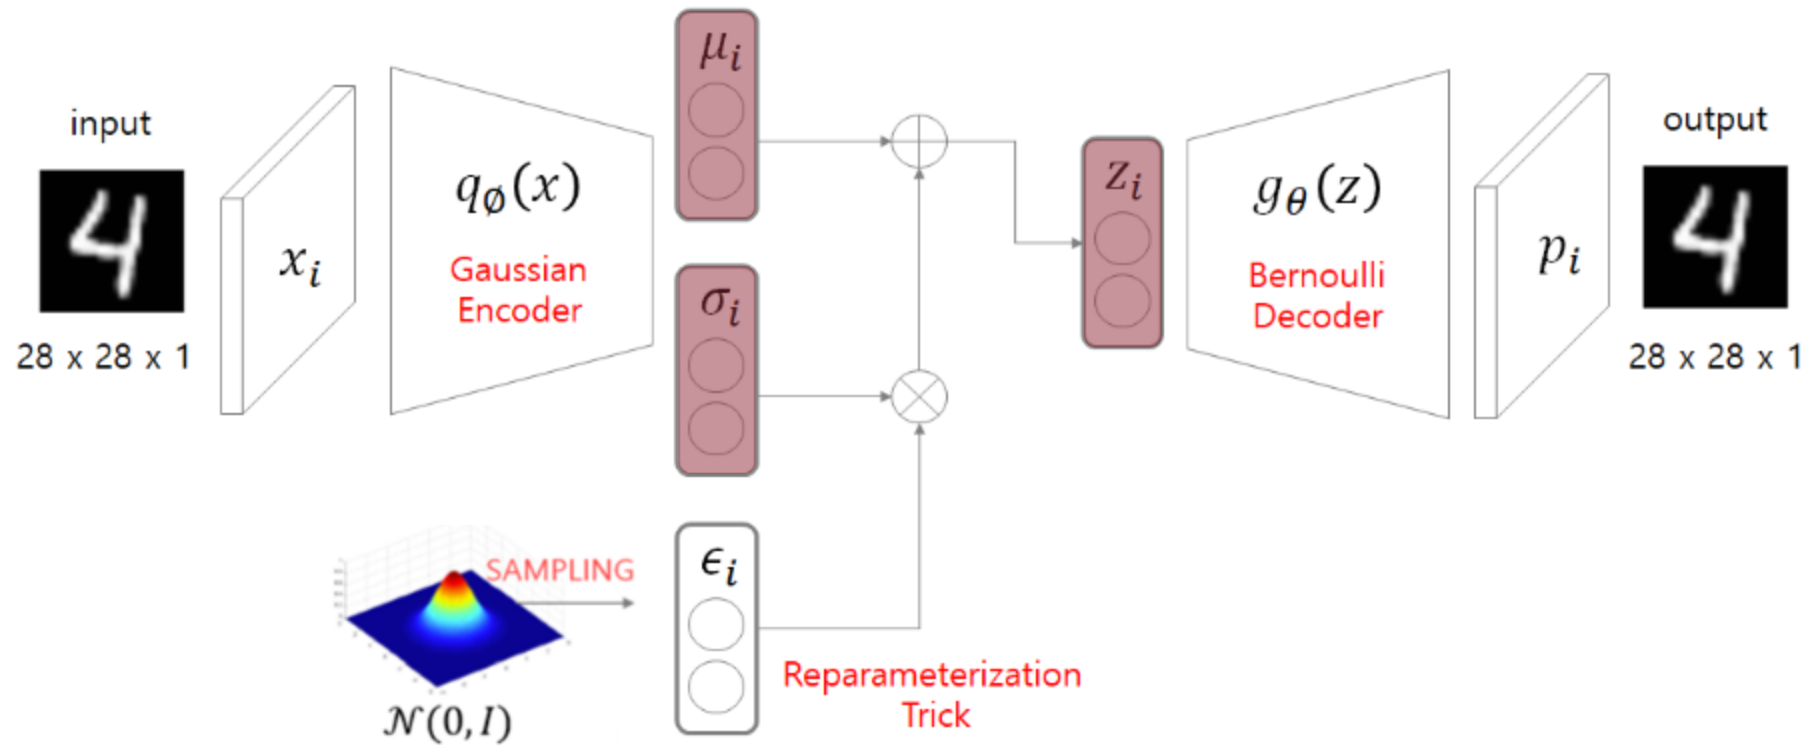
# 03 Variational Autoencoder (VAE)



\* <https://taeu.github.io/paper/deeplearning-paper-vae/>



# 03 Variational Autoencoder (VAE)



\* <https://taeu.github.io/paper/deeplearning-paper-vae/>



# 03 VAE - Loss function

Loss function = Reconstruction error + Regularization

## Reconstruction error


$$-\sum_{j=1}^D x_{i,j} \log p_{i,j} + (1 - x_{i,j}) \log(1 - p_{i,j})$$

- Bernoulli's distribution 가정 → Cross entropy 형태 (기본 가정)
- Normal distribution 가정 → MSE 형태



## Regularization

$$\frac{1}{2} \sum_{j=1}^J (\mu_{i,j}^2 + \sigma_{i,j}^2 - \ln(\sigma_{i,j}^2) - 1)$$



KL Divergence

$$KL(q_\phi(z|x_i) || p(z))$$

Input  $x_i$  가 encoder를 통과 한 후 나온 확률 분포



DL Based

03

# Generative Adversarial Networks (GAN)


**종료**

**Sequence Generative Adversarial Net with Policy Gradient**  
Yoon Sang Cho

18.02.08

---

Sequence Generative Adversarial Nets wi

발표자:  **조윤상**

📅 2018년 2월 9일  
🕒 오후 1시 ~  
📍 고려대학교 신공학관 218호


[세미나 정보 보기 →](#)

**종료**

**AmbientGAN: Generative models from lossy measurements**

---

AmbientGAN: Generative models from lo:

발표자:  **이한규**

📅 2018년 5월 18일  
🕒 오후 1시 ~  
📍 고려대학교 신공학관 218호

[세미나 정보 보기 →](#)


**종료**

Autoregressive Generative Models  
PixelRNN, PixelCNN and WaveNet

2019-07-05  
곽민구

---

Autoregressive Generative Models: PixelF

발표자:  **곽민구**

📅 2019년 7월 5일  
🕒 오후 1시 ~  
📍 고려대학교 신공학관 218호

[세미나 정보 보기 →](#)

**종료**

준비 중입니다

---

ACGAN : Auxiliary Classifier GANs

발표자:  **신욱수**

📅 2022년 2월 18일  
🕒 오후 1시 ~  
📍 고려대학교 신공학관 218호  
▶ 온라인 비디오 시청 (YouTube)

[세미나 정보 보기 →](#)


**종료**

Generative Adversarial Network for Imbalanced data

DMQA Open Seminar  
2023.06.30  
백민재

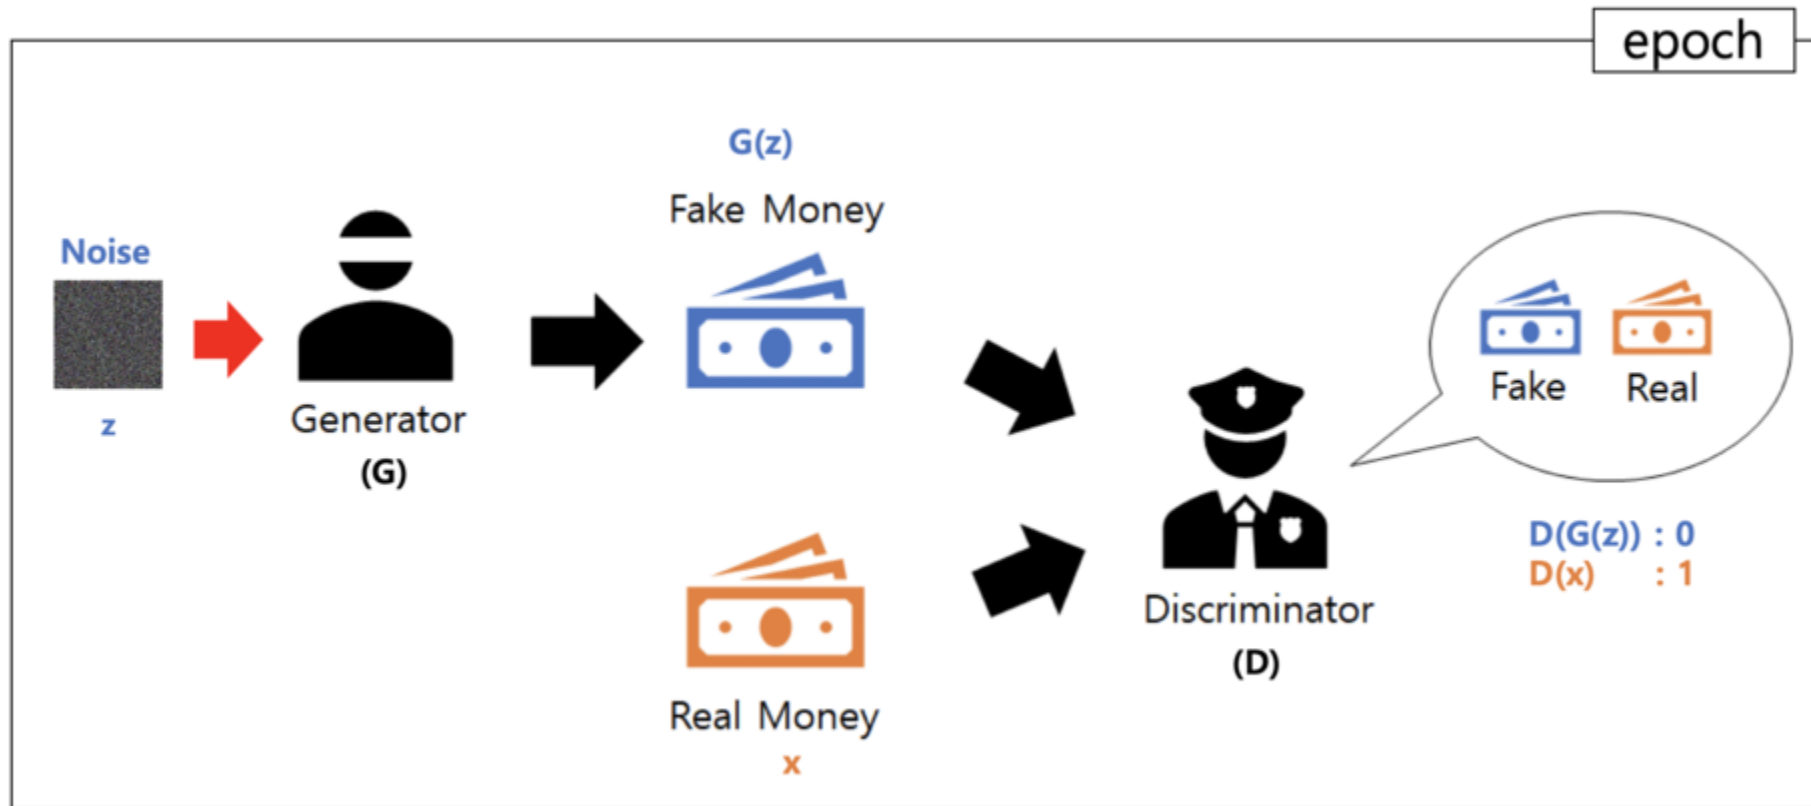
---

Generative Adversarial Network for Imba

발표자:  **백민재**

📅 2023년 6월 30일  
🕒 오후 1시 ~  
▶ 온라인 비디오 시청 (YouTube)

[세미나 정보 보기 →](#)




\* <https://baechu-story.tistory.com/12>



# 03 Deep Convolutional GANs (DCGAN)

## GAN의 문제점


step 1 Fri Aug 20 2021 03:13:31 GMT+0900 (한국 표준시)



샘플에 blur가 되거나, 이해할 수 없는 이미지 생성 등 결과가 불안정

## DCGAN의 목적과 구조

GAN에 CNN을 적용



\* <https://velog.io/@a01152a/%EB%85%BC%EB%AC%B8-%EC%9D%BD%EA%B8%B0-%EB%B0%8F-%EA%B5%AC%ED%98%84-DCGAN>






# Deep Convolutional GANs (DCGAN)

## DCGAN의 목적과 구조

GAN에 CNN을 적용



## 세부 특징

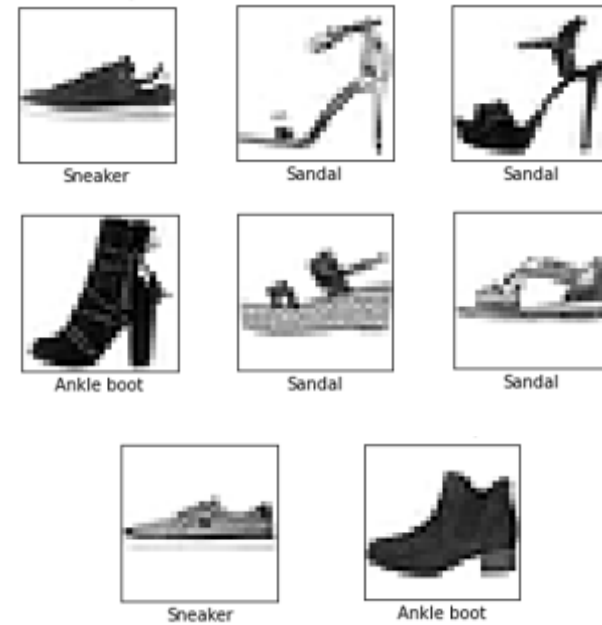
- 모든 max pooling layer를 Convolutional stride, fractionally-strided convolution 으로 변환하여 feature-map의 크기를 조절
- Batch Normalization 적용 (Generator의 output layer와 Discriminator의 input layer 제외)
- Fully connected layer 제거
- Generator의 output에는 Tanh를 사용하고, 나머지는 ReLU를 사용
- Discriminator의 모든 layer에 LeakyReLU를 사용

\* <https://velog.io/@a01152a/%EB%85%BC%EB%AC%B8-%EC%9D%BD%EA%B8%B0-%EB%B0%8F-%EA%B5%AC%ED%98%84-DCGAN>



DL Based

# 03 Conditional GANs (CGAN)


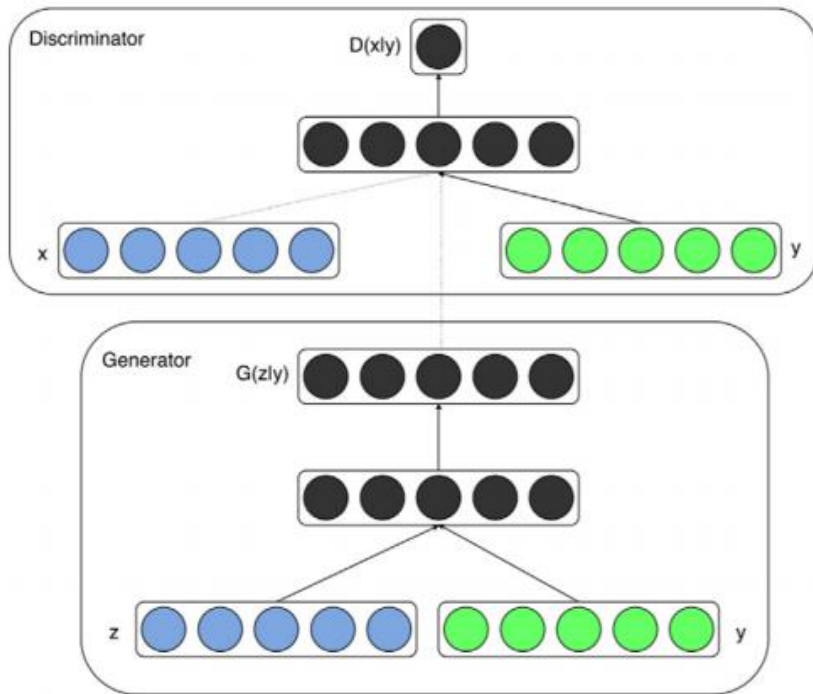




# 03 Conditional GANs (CGAN)

## 핵심 아이디어

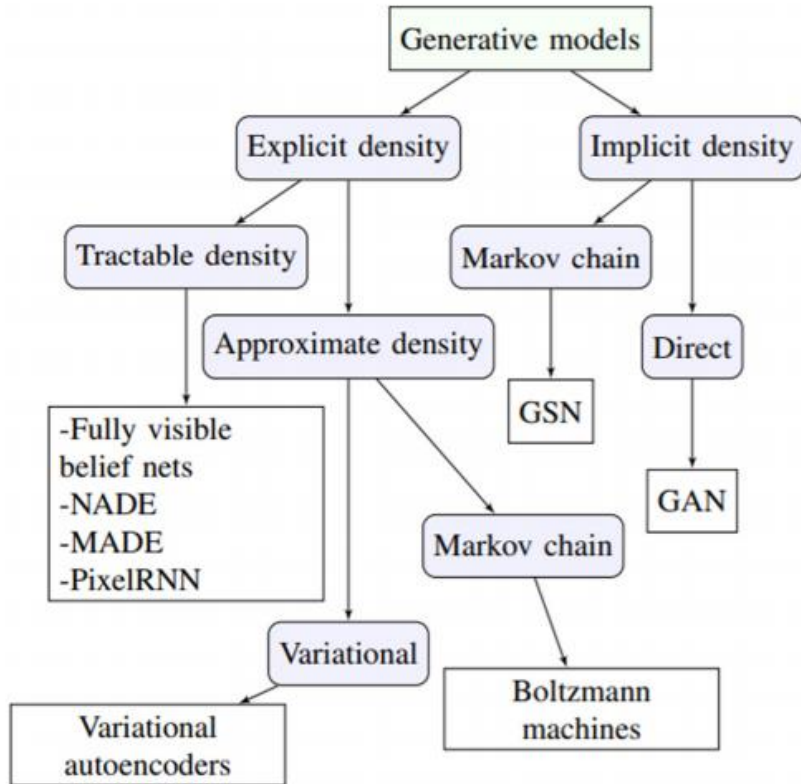
- G와 D가 동시에 condition인 class label  $y$ 를 추가 입력으로 받음



<Discriminator의 작동>

\*<https://velog.io/@wilko97/Conditional-GAN>

# 04 Analysis



## Explicit density estimation

- 실제 확률 밀도 함수  $P_{model(x)}$ 을 정의하고 최적화하여 문제 해결
- 확률 분포를 분석하고 이해하는데 유용
- 예측의 불확실성을 정량화 할 수 있음
- 다변량 가우시안 분포, VAE, BM 등

## Implicit density estimation

- 실제 확률 밀도 함수  $P_{model(x)}$ 을 명시적으로 정의하지 않고  $P_{model(x)}$ 에서 샘플링할 수 있는 모델을 학습하는 것
- 복잡한 데이터 분포 모델링에 강점을 가지며, 종종 사실적 샘플 생성 가능
- GAN, GSN 등



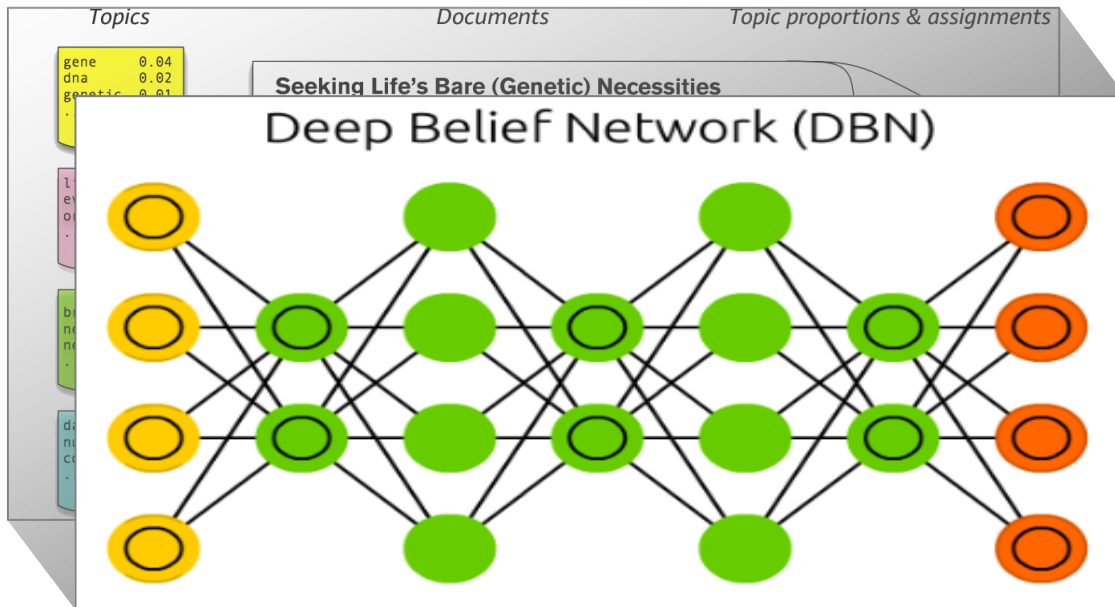
# 04 Analysis

Model	Density estimation	Advantages	Disadvantages
GMM		공분산 조건에 따라 다양한 클러스터 모양을 허용	Mixed Membership이 항상 최선의 선택은 아님
		데이터가 여러 클러스터에 대한 Mixed Membership을 가짐	고차원 데이터에서 성능 발휘가 어려움
HMM	Explicit	강력한 통계적 기반, 단순한 개념, 유연성	많은 수의 알려지지 않은 parameter와 시퀀스 간 상관관계를 이해하지 못함
LDA		확장 가능하며 새로운 데이터 포인트에 적용 가능	주제에 대한 사전지식 필요
RBM		고차원의 상관관계를 표현하는데 효과적	계산 비용이 많이 들고 수렴 시간이 불확실
DBN		패턴 인식을 위한 강력한 extractor가 됨	복잡한 훈련 절차가 필요함
		소량의 label 데이터로도 fine-tuning 가능	Markov chain이 필요함
DBM		효율적 특징 추출과 높은 성능	Markov chain이 필요하고, 훈련 절차가 복잡함
VAE		Likelihood가 높으며, 모델 평가의 객관적 기준이 존재	생성된 샘플들이 선명하지 못함
GANs	Implicit	빠르고 샘플의 질이 높음	Nash equilibrium이 필요하며, 평가가 어려움

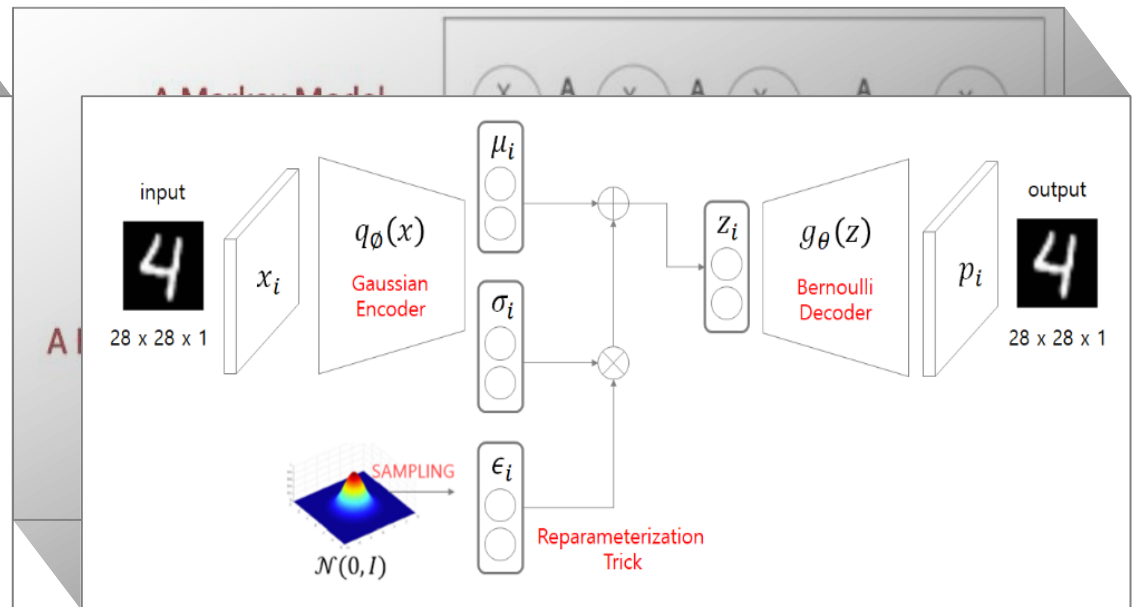


# 04 Analysis

## Topic Modeling



## Pattern recognition








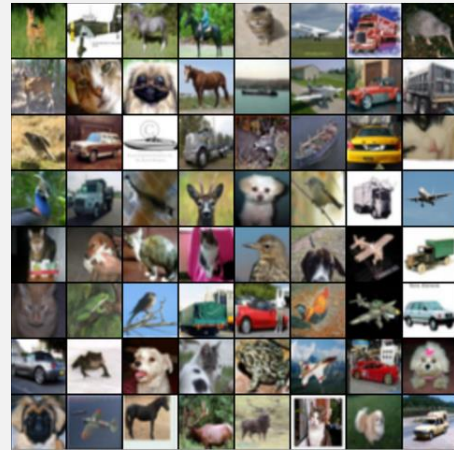
# 04 Difficulty of analysing generated samples

논문에서 생성한 이미지

<MNIST dataset using VAE>



<CIFAR-10 dataset using DCGAN>




"GAN이 이미지 생성에 항상 더 우수한 것은 아님"

약한 확률 모델도 좋은 이미지를 얻을 수 있음

<Training data>



<Generated data>



"고품질의 이미지가 생성되었다고 하더라도 올바르게 훈련되진 않음"

→ 생성 관점에서 unbiasedly evaluating 한 방법이 필요



# Conclusion

## 각 생성모델 별 적합한 적용 분야

Model	Deployed in fields	Model	Deployed in fields	Model	Deployed in fields
GMM	클러스터링, 음향 분석	HMM	DNA 시퀀스 분석, 음성 패턴 인식	LDA	차원 축소, 주제 모델링
RBM	차원 축소, 회귀/분류, 토픽 모델링, CF	DBN	분류, 음성 인식, 정보 검색, 신약 개발	DBM	패턴 인식, 정보 검색, 회귀/분류
VAE	이미지 예측, CF, 음향, 분자 설계 모델링	GAN	신약 개발, 이상치 탐지, 이미지 분석	DCGAN	이미지 생성
FCCGAN	고품질 이미지 생성	CGAN	얼굴 생성, 노화 예측, 음성 정제, 언어 인식	SGAN	Text-to-image 생성, Transformation

\*CF : Collaborative filtering

## 미래 연구 방향

- Generative modeling의 미래 방향은 **두 개 이상의 modeling을 혼합** 하는 것
  - HMM과 LDA는 줄기 세포 연구, 주제 모델링, 그리고 음성 감정 인식이 공동으로 사용
  - SGAN을 사용한 텍스트에서 이미지 생성
  - 상황 인식 텍스트에서 이미지 생성을 위해 VAE와 GAN을 섞음





**고맙습니다**

