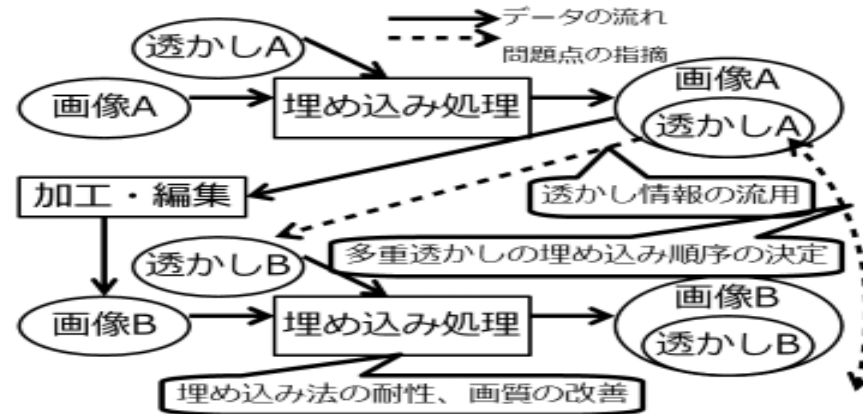


# CNNの中間層とVAEの 電子透かしへの応用

木下研究室 201403762 牛山 尚織

# 研究動向と問題点

- ▶ 一般的な電子透かしでは、透かし情報をコピーされてほかのコンテンツに利用される可能性がある。
- ▶ また、二次利用による多重の電子透かしの優先順位や加工内容との加工関係を明確にできない。



# 目的

- ▶ CNNの中間層を用いた知覚ハッシュの構成法
- ▶ 2件前の発表(小藤田)  
中間層の位相幾何学的構造→知覚ハッシュ値
- ▶ 1件前の発表(小澤)  
中間層のプーリング層の512個のノードを主成分分析→知覚ハッシュ値
- ▶ 本研究
  - ▶ 画像の中間層を用いた、VAE/GANによる知覚ハッシュ値の生成

# 研究の概要(中間層情報の生成)

画像の特徴を抽出するために中間層の情報を利用

Signal : 知覚ハッシュ値を求める対象の画像の集合 (100枚)

Noise : Signal以外の画像の集合 (200枚)

画像の変形  
による学習  
データオー  
グメンテー  
ション  
(keras)

(原画像から複数の  
変形画像を作成)



Signalとしての画像



Noiseとしての画像

入力

kerasの学習済みモ  
デルVGG16を用い  
たFine-Tuning

出力

カテゴリSignal


入力

Convolutional  
Neural Network

出力

カテゴリNoise

中間層の情報を抽出



Signalの画像を入力したとき、出力が  
クラスSignalとなり、Noiseの画像を  
入力したときには、出力がクラス  
Noiseになるように学習させる

# 研究の概要(データオーグメンテーション)

画像の特徴を抽出するために中間層の情報を利用

Signal : 知覚ハッシュ値を求める対象の画像の集合 (100枚)

Noise : Signal以外の画像の集合 (200枚)

画像の変形  
による学習  
データオー  
グメンテー  
ション  
(keras)

(原画像から複数の  
変形画像を作成)



Signalとしての画像



Noiseとしての画像


入力

入力

kerasの  
デルタ  
な

Conv  
Neu

・ Jupyter Notebook上で画像処理  
ライブラリであるOpenCVを使い、  
回転、移動、拡大、縮小させた画  
像を用意する。



Signalの画像を入力したとき、出力が  
クラスSignalとなり、Noiseの画像を  
入力したときには、出力がクラス  
Noiseになるように学習させる

# 研究の概要(データオーグメンテーション)

画像の特徴を抽出するために中間層の情報を利用

Signal : 知覚ハッシュ値を求める対象の画像の集合 (100枚)

Noise : Signal以外の画像の集合 (200枚)

画像の変形  
による学習  
データオー  
グメンテー  
ション  
(keras)

(原画像から複数の  
変形画像を作成)



Signalとしての画像



Noiseとしての画像

入力


入力

kerasの  
デルV  
たFi


Neu

- ・ 本実験では、Signalとしての原画像から、加工・編集を行った画像100枚ずつ
- ・ その他の画像として、違う種類の画像を加工・編集を行った画像と、複数の類似画像100枚ずつ



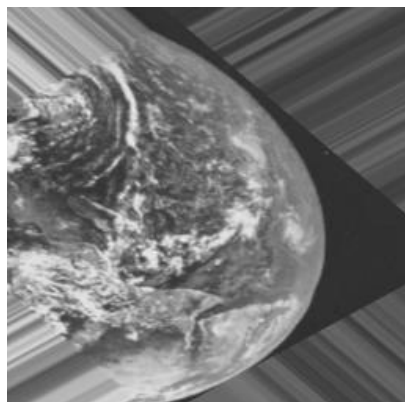
Noiseになるように学習させる



# 提案手法 (データオーグメンテーション2)



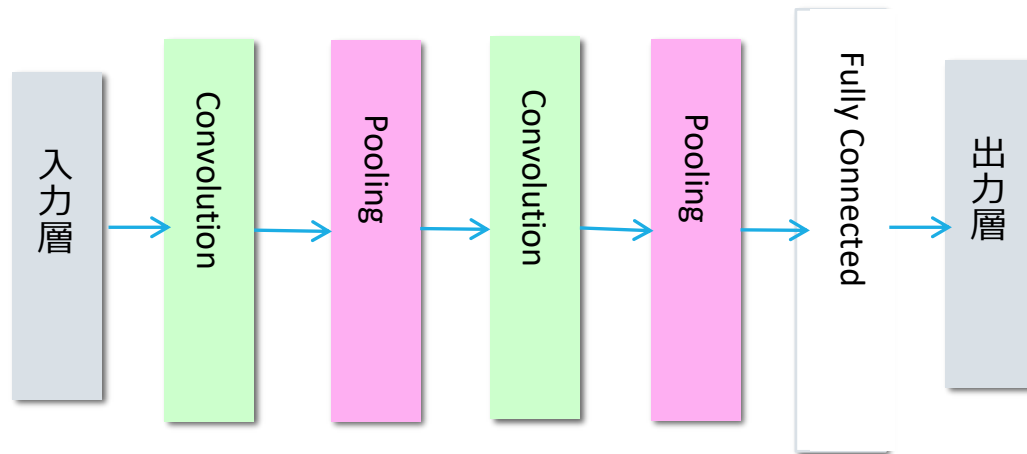
Signalとしての画像集合  
(girl)



Noiseとしての変形画像と複数の類似画像  
(earthと寿司)

# 畳み込みニューラルネットワーク ワーク(CNN)

- ▶ 畳み込みニューラルネットワーク(CNN)は、「畳み込み層」や「プーリング層」などのいくつかの層をもつニューラルネットワークで、画像認識の分野で特に優れた性能を発揮しています
- ▶ 画像内の特徴量を圧縮することで、画像の変形などに強くすることで計算量を下げることができる





# VAE (Variational Auto Encoder)

- ▶ 入力 → 潜在変数の分布の生成  $P(\theta | Y)$

$\theta$ : 潜在変数

- ▶ 潜在変数からのサンプリング


→ 入力に近い出力の生成  $P(Y | \theta)$

$P(\theta | Y)$




入力

潜在変数の  
分布の生成



潜在変数の  
サンプリング

$P(Y | \theta)$




出力

# MNIST

(Mixed National Institute of Standards and Technology database)

- ▶ MNIST(Mixed National Institute of Standards and Technology database)とは、手書き数字画像60,000枚と、テスト画像10,000枚を集めた、画像データセット
- ▶ 画像データと画像に書かれた数字の正解となるラベルデータで構成されている

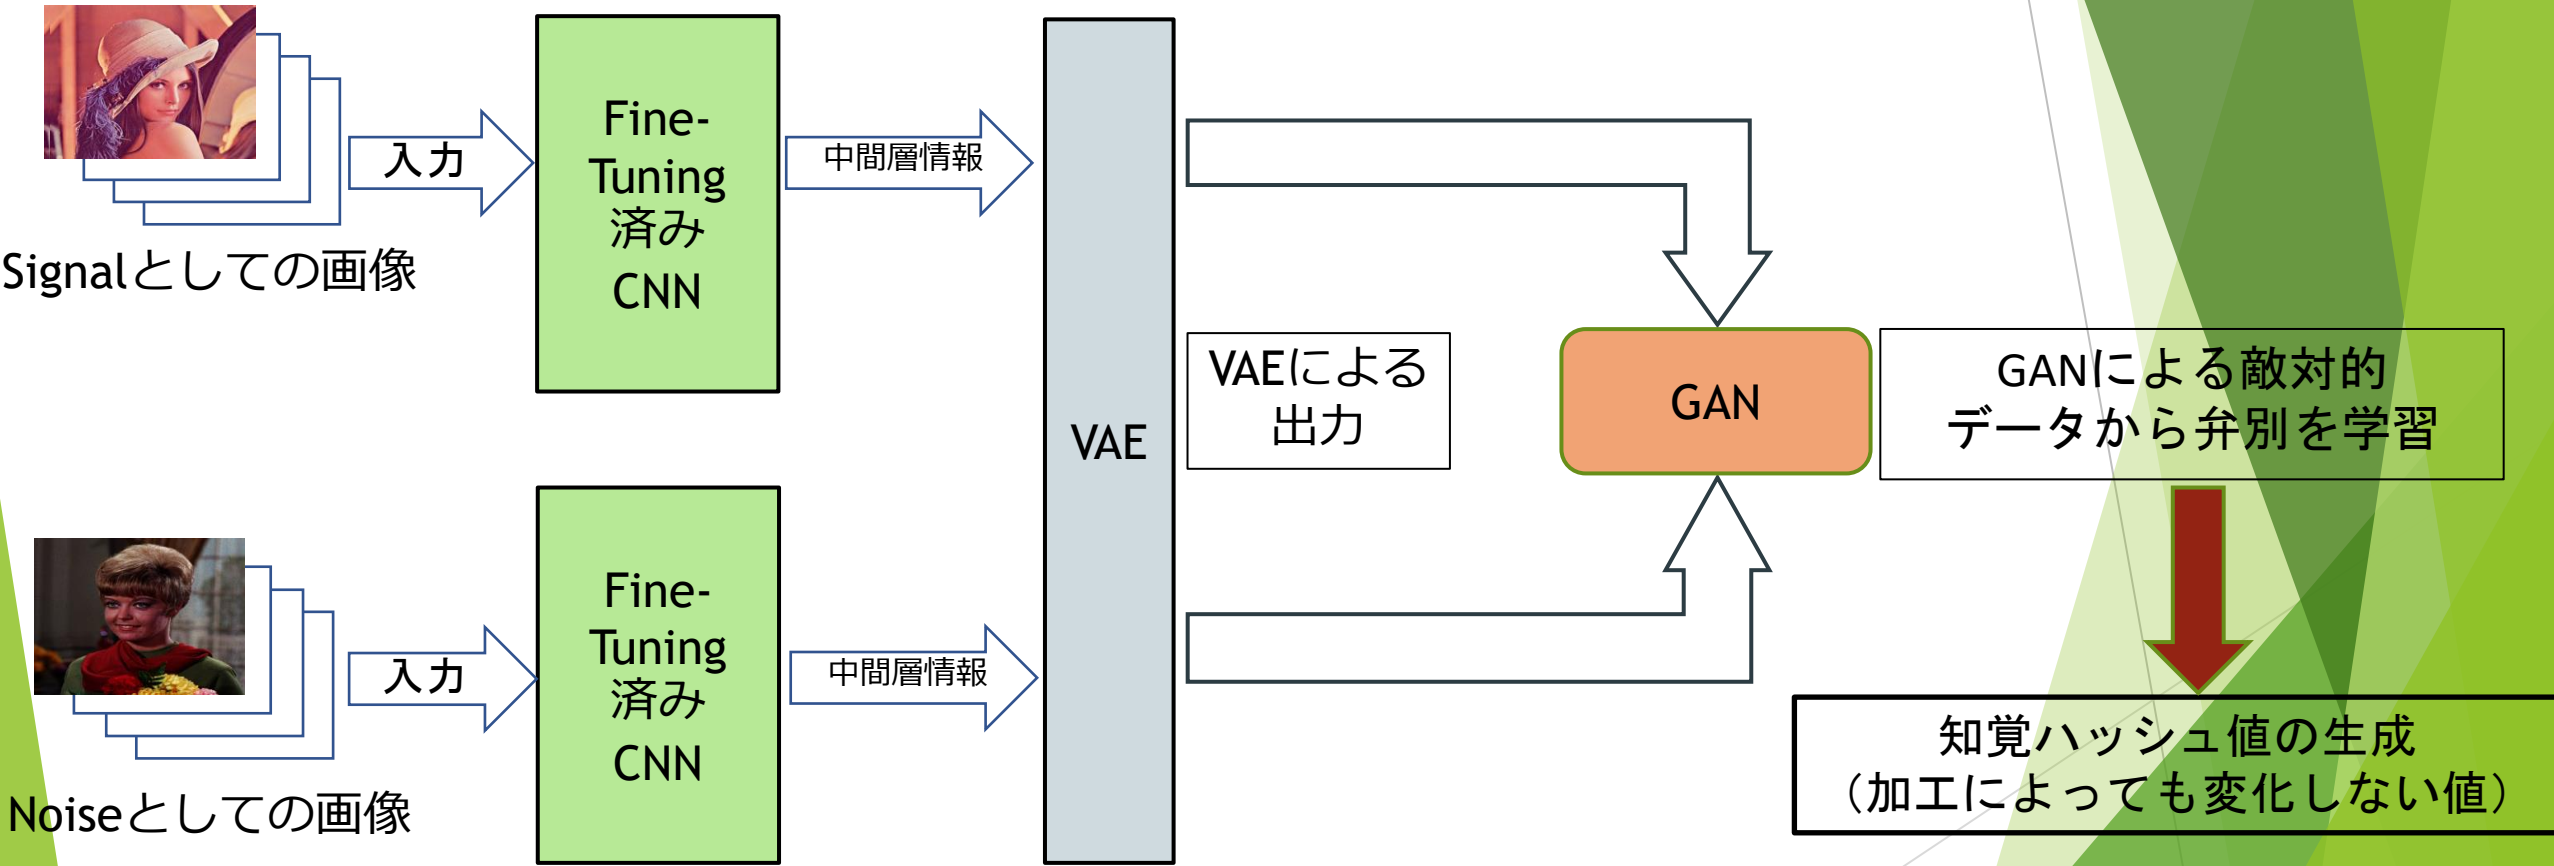


# GAN

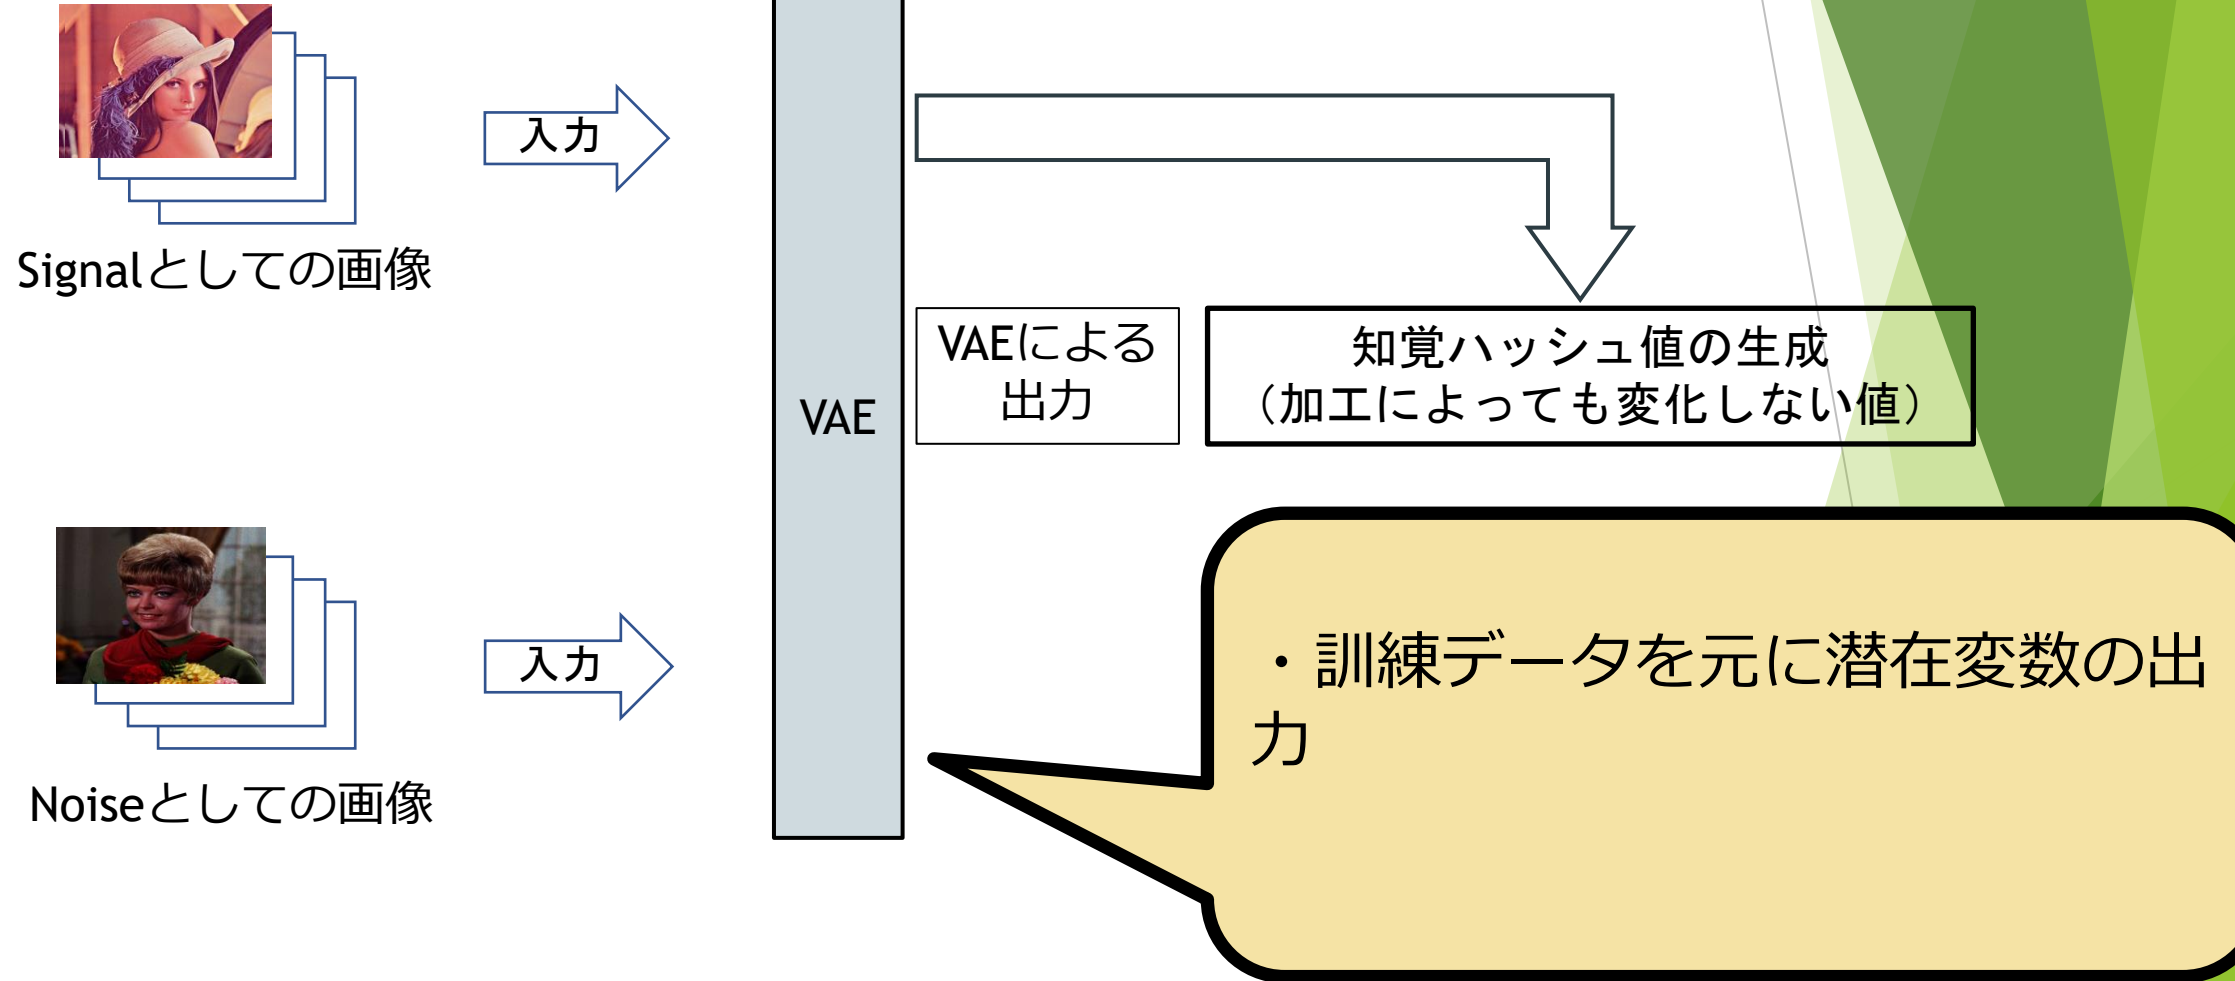
## (Generative Adversarial Networks)

- ▶ GANは、敵対的生成ネットワークのことで、正解データを与えることなく特徴を学習する生成モデル
- ▶ データから特徴を学習することで、実在しないデータを生成したり、存在するデータの特徴に沿って変換できる

# 研究の概要(中間層情報のVAE/GANによる解析)



# 研究の概要(VAEのみによる解析)

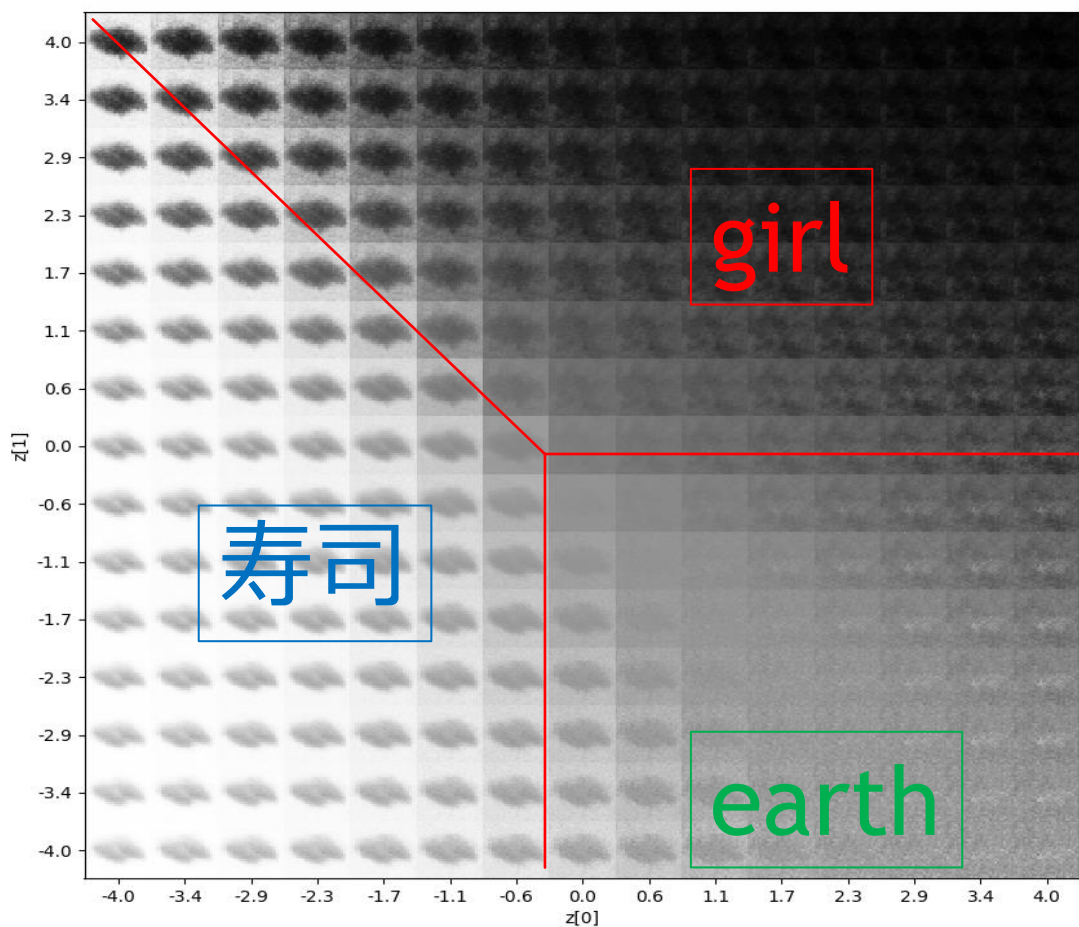


# VAEの実装


VAEのMNISTによる、画像生成のサンプルプログラムからSignalとNoiseの画像を読み込み、潜在変数の分布を出力する

対象が画像情報なので、潜在変数は2次元で説明される


# 出力画像のクラスタリング された2次元マップ



VAEは通常このように画像が分類されて、それぞれの画像集合の特徴は2次元マップのクラスター上に潜在変数 $Z$ として分布している



girl




earth



寿司

# 潜在変数 $Z$ の分布



3つの画像の潜在的確率変数 $Z$ の  
2次元マップがVAE出力の一つで  
ある


**赤点** : Signalの集合

**緑点** : Noiseの集合 1

**青点** : Noiseの集合 2



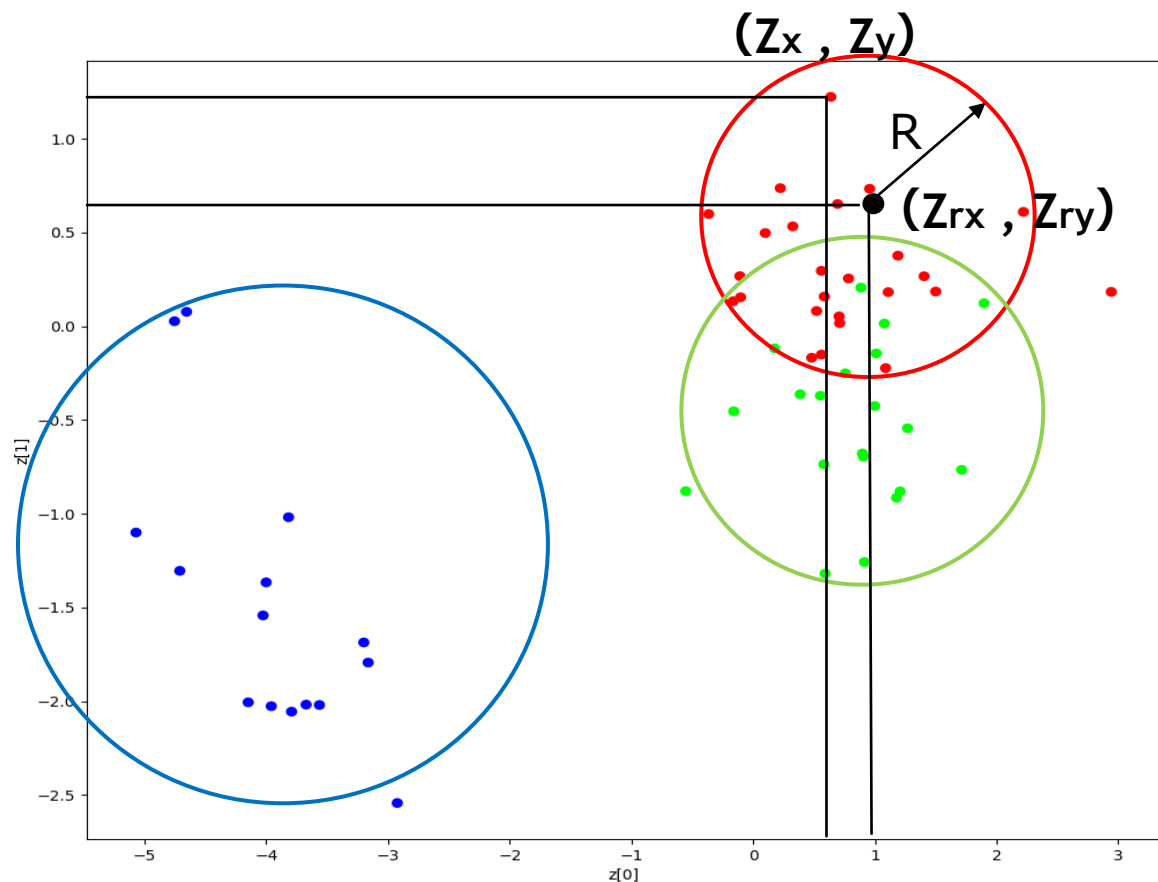
# 潜在変数 $z$ の分布



赤と緑は、それぞれ同一の画像を加工・編集した画像であり、一定の範囲に集中して分布している

この分布が、加工・編集に影響されない画像の特徴と考えられる

# 知覚ハッシュ値の導出



赤点 : Signalの集合

緑点 : Noiseの集合 1

青点 : Noiseの集合 2

2次元潜在変数の分布から重心を取り、  
知覚ハッシュ値として値をとる

$$\text{重心(知覚ハッシュ)} = \left( \frac{\sum Zrx}{N}, \frac{\sum Zry}{N} \right)$$

$$\sqrt{\left( Zx - \frac{\sum Zrx}{N} \right)^2 + \left( Zy - \frac{\sum Zry}{N} \right)^2} \leq R$$

# まとめ

- ▶ VAEに画像を直接入力することだけで、出力した2次元潜在変数の分布から重心を取ることで、知覚ハッシュ値の生成をすることができた
- ▶ 今後の課題としては、実験結果より2次元潜在変数の分布が重複しているため、GANの敵対的学習により厳密に弁別できるように学習させることがあげられる