

Generative Adversarial Network for Imbalanced data

DMQA Open Seminar

2023.06.30

백민재



- **백민재(Min Jae Baek)**

- 고려대학교 산업경영공학과 재학 중
- Data Mining & Quality Analytics Lab(김성범 교수님 연구실)
- 석사 과정(2022.03 ~)

- **연구 관심 분야**

- Machine learning & Deep learning Algorithms
- Multivariate Time Series Data

- **E-mail**

- minjae7306@korea.ac.kr

Contents


- Introduction
 - Imbalanced data
 - Briefly review about machine learning for imbalanced data
- Generative Adversarial Network for imbalanced data
 - BAGAN: Data Augmentation with Balancing GAN
 - IDA-GAN: A Novel Imbalanced Data Augmentation GAN
 - Enhanced balancing GAN: minority-class image generation
- Conclusion

Introduction


Introduction

❖ 불균형 데이터(Imbalanced data)

- 클래스 간 샘플 수의 불균형을 가진 데이터셋
 - 이진 불균형 데이터 : 한 클래스의 샘플 수가 다른 클래스에 비해 지나치게 적은 데이터를 의미
 - 다중 클래스 불균형 데이터 : 하나 이상의 클래스가 다른 클래스에 비해 샘플 수가 현저히 적은 것을 의미
- 실제 세계의 많은 문제에서 불균형 데이터가 발생하며, 암 진단, 사기 탐지, 이상 감지 등 다양한 분야에서 흔히 관찰됨



이진 불균형 데이터




다중 클래스 불균형 데이터


Introduction

❖ 불균형 데이터의 문제점

- 분류 모델의 편향
 - 불균형 데이터셋에서는 다수 클래스에 초점이 맞추어지기 때문에 분류 모델이 주로 다수 클래스로 편향되어 학습될 수 있음
- 소수 클래스 분류의 어려움
 - 소수 클래스의 Sample이 부족하거나 대표성이 떨어질 경우, 해당 클래스를 정확하게 분류하는 것이 어려움



이상적인 분류



편향된 분류

Introduction


❖ 불균형 데이터를 위한 머신러닝 방법

- 언더 샘플링 (Undersampling): 다수 클래스의 샘플을 일부만 선택하여 데이터셋을 균형있게 만드는 방법
- 오버 샘플링 (Oversampling): 소수 클래스의 샘플을 복제하거나 합성하여 데이터셋을 균형있게 만드는 방법
- 재샘플링 (Resampling): 재샘플링 알고리즘을 사용하여 Synthetic 샘플을 생성하는 방법
 - SMOTE(Synthetic Minority Over-sampling Technique)
 - ADASYN(Adaptive Synthetic Sampling)
 - GAN(Generative Adversarial Network)


Introduction

❖ 불균형 데이터를 위한 머신러닝 방법

- 언더 샘플링 (Undersampling): 다수 클래스의 샘플을 일부만 선택하여 데이터셋을 균형있게 만드는 방법
- 오버 샘플링 (Oversampling): 소수 클래스의 샘플을 복제하거나 합성하여 데이터셋을 균형있게 만드는 방법



언더 샘플링



오버 샘플링

Introduction


❖ 불균형 데이터를 위한 머신러닝 방법

- 언더 샘플링 (Undersampling): 다수 클래스의 샘플을 일부만 선택하여 데이터셋을 균형있게 만드는 방법
- 오버 샘플링 (Oversampling): 소수 클래스의 샘플을 복제하거나 합성하여 데이터셋을 균형있게 만드는 방법
- 재샘플링 (Resampling): 재샘플링 알고리즘을 사용하여 Synthetic 샘플을 생성하는 방법
 - SMOTE(Synthetic Minority Over-sampling Technique)
 - ADASYN(Adaptive Synthetic Sampling)
 - GAN(Generative Adversarial Network)

Introduction

❖ 불균형 데이터를 위한 머신러닝 방법


- 재샘플링 (Resampling): 재샘플링 알고리즘을 사용하여 Synthetic 샘플을 생성하는 방법
 - SMOTE(Synthetic Minority Over-sampling Technique)
 - 소수 클래스 데이터 포인트와 가장 가까운 이웃 데이터 포인트 사이의 차이를 이용하여 새로운 데이터 포인트를 생성



Introduction

❖ 불균형 데이터를 위한 머신러닝 방법


- 재샘플링 (Resampling): 재샘플링 알고리즘을 사용하여 Synthetic 샘플을 생성하는 방법
 - ADASYN(Adaptive Synthetic Sampling)
 - SMOTE와 유사한 방법이지만 각 클래스의 밀도를 고려하여 데이터 증강



Introduction


❖ 불균형 데이터를 위한 머신러닝 방법

- 재샘플링 (Resampling): 재샘플링 알고리즘을 사용하여 Synthetic 샘플을 생성하는 방법
 - GAN(Generative Adversarial Network)
 - Generator 와 Discriminator 를 경쟁시켜 실제와 유사한 샘플을 생성하여 데이터를 증강



Introduction

종료 찾추기 쉬운 샘플에 대한 기여도를 줄이고 어려운 샘플의 기여도를 높이는 방식
의 예측 정확도를 통해 학습 난이도를 반영함



Handling Imbalanced Data

발표자:  정진용

 2022년 5월 27일

 오후 1시 ~

 고려대학교 신공학관 218호

 온라인 비디오 시청 (YouTube)

세미나 정보 보기 →

종료 Open DMQA Seminar

Handling imbalanced datasets

2021.11.19

Data Mining & Quality Analytics Lab.
발표자 : 황하은

Handling imbalanced datasets

발표자:  황하은

 2021년 11월 19일

 오후 1시 ~

 온라인 비디오 시청 (YouTube)

세미나 정보 보기 →

Generative Adversarial Network for Imbalanced data

Generative Adversarial Network for imbalanced data

Paper

❖ BAGAN: Data Augmentation with Balancing GAN

- Mariani, Giovanni, et al. "Bagan: Data augmentation with balancing gan." arXiv preprint arXiv:1803.09655 (2018).

BAGAN: Data Augmentation with Balancing GAN

Giovanni Mariani, Florian Scheidegger, Roxana Istrate, Costas Bekas, and Cristiano Malossi
IBM Research – Zurich, Switzerland

Abstract

Image classification datasets are often imbalanced, characteristic that negatively affects the accuracy of deep-learning classifiers. In this work we propose balancing GAN (BAGAN) as an augmentation tool to restore balance in imbalanced datasets. This is challenging because the few minority-class images may not be enough to train a GAN. We overcome this issue by including during the adversarial training all available images of majority and minority classes. The generative model learns useful features from majority classes and uses these to generate images for minority classes. We apply class conditioning in the latent space to drive the generation process towards a target class. The generator in the GAN is initialized

enables BAGAN to learn underlying features of the specific classification problem starting from all images and then to apply these features for the generation of new minority-class images. For example, let us consider the classification of road traffic signs [1]. All warning signs share the same external triangular shape. Once BAGAN learns to draw this shape from one of the signs, we can apply it for drawing any other one. Since BAGAN learns features starting from all classes whereas the goal is to generate images for the minority classes, a mechanism to drive the generation process toward a desired class is needed. To this end, in this work we apply class conditioning on the latent space [2, 3]. We initialize the discriminator and generator in the GAN with an autoencoder. Then, we leverage this autoencoder to learn class

BAGAN: Data Augmentation with Balancing GAN

❖ 불균형 데이터 입력에 대한 GAN 의 한계


◆ 일반 GAN의 입력으로 불균형 데이터를 사용

- 소수 클래스(Minority class)만을 GAN의 입력으로 사용할 경우
 - 데이터의 부족으로 GAN의 학습이 제대로 이루어지지 못함
 - 전체 데이터를 입력으로 사용해야 함
- 전체 데이터 (다수 클래스(Majority class) 및 소수 클래스)를 입력으로 사용할 경우
 - GAN의 학습이 다수 클래스의 생성에 더욱 집중됨
 - GAN이 서로 다른 클래스를 명시적으로 구별하도록 해야함
 - ✓ ACGAN(Auxiliary Classifier GAN)

BAGAN: Data Augmentation with Balancing GAN

❖ ACGAN(Auxiliary Classifier GAN)

- Generator(G) 와 Discriminator(D) 모두에게 추가적인 정보로써 클래스 레이블을 제공하여 학습
 - G : 노이즈 벡터와 원하는 클래스 레이블을 입력으로 받아 해당 클래스에 속하는 이미지를 생성
 - D : 생성된 이미지의 가짜/진짜를 평가하는 동시에, 이미지가 어떤 클래스에 속하는지도 분류



ACGAN 구조

종료


준비 중입니다

ACGAN : Auxiliary Classifier GANs

발표자:  신옥수

📅 2022년 2월 18일

🕒 오후 1시 ~

📍 고려대학교 신공학관 218호

📺 온라인 비디오 시청 (YouTube)

세미나 정보 보기 →

BAGAN: Data Augmentation with Balancing GAN

❖ 불균형데이터 입력에 대한 GAN 의 한계

◆ ACGAN의 입력으로 불균형 데이터를 사용


- 전체 데이터 (다수 클래스 및 소수 클래스)를 입력으로 사용
 - 다수 클래스에 대한 정보는 많이 학습 되지만 소수 클래스에 대한 정보가 부족
 - 소수 클래스에 관하여 G 가 만든 이미지는 D 에 의해 가짜로 판단
 - G 는 소수 클래스를 진짜라고 판단 받기 위해 다수 클래스의 정보를 가져와서 진짜 같은 이미지 생성
 - 진짜 소수 클래스 와는 달리 품질이 저하된 이미지가 생성될 수 있음

◆ ACGAN의 입력으로 Imbalanced MNIST data를 사용

- 0 클래스를 97%제거하여 소수 클래스로 만든 MNIST를 사용



ACGAN으로 생성한 MNIST 0 이미지





BAGAN: Data Augmentation with Balancing GAN

❖ BAGAN

◆ Discriminator 의 출력을 Fake/Class 출력으로 변경


- G 는 Fake Label 을 피하고 원하는 Class Label 과 일치하도록 학습
- G 는 Class Label 과 일치하지 않으면 실제처럼 보이는 이미지를 생성해도 보상을 받지 못함
 - ACGAN은 대상 소수 클래스를 대표하지 않는 이미지를 그려도 G 가 보상을 받을 수 있었음




BAGAN: Data Augmentation with Balancing GAN

❖ BAGAN


Step1 Autoencoder training



Step2 GAN initialization



Step3 GAN training




BAGAN: Data Augmentation with Balancing GAN

❖ BAGAN

◆ Step1 Autoencoder(AE) training

- AE를 훈련 데이터 세트의 모든 이미지(다수클래스 및 소수클래스)를 사용하여 학습
- AE는 다수 클래스와 소수 클래스의 모든 이미지를 처리(전체 데이터의 분포를 추론)
- L2 손실(Loss) 최소화
- AE의 가중치는 GAN 모듈로 전송되어 GAN을 초기화하는데 사용

Step1 Autoencoder training




BAGAN: Data Augmentation with Balancing GAN

❖ BAGAN


◆ Step2 GAN initialization

- GAN Generator(G)는 AE의 Decoder(D) 가중치로 초기화 실시
 - Class 별 특성을 학습하고 Mode collapse를 방지하기 위해 D 가중치를 사용
- GAN Discriminator(D_d)는 AE의 Encoder(E) 가중치로 초기화 실시
 - 이미지를 분류하는 데 도움이 될 수 있는 의미 있는 특징을 포함하기 위해 E 가중치 사용
 - Discriminator의 마지막 Layer는 Softmax 함수가 있는 Dense Layer(D_c)로 구성되며 GAN 훈련 중 학습됨

Step1 Autoencoder training



Step2 GAN initialization




BAGAN: Data Augmentation with Balancing GAN

❖ BAGAN


◆ Step2 GAN initialization

- Class conditional latent vector generator
 - Class label (c)을 입력으로 해당 클래스의 특성을 반영하는 latent vector Z_c 를 출력하는 프로세스
 - 훈련 데이터 세트의 모든 Class (c)의 실제 이미지 (X_c)를 고려하여 $Z_c = E(X_c)$ 의 분포와 일치하도록 μ_c 와 Σ_c 를 계산
 - $N_c = N(\mu_c, \Sigma_c)$, μ_c : 평균 벡터, Σ_c : 공분산 행렬
 - N_c (확률 분포)로 Class conditional latent vector generator 초기화

Step1 Autoencoder training



Step2 GAN initialization




BAGAN: Data Augmentation with Balancing GAN

❖ BAGAN

◆ Step3 GAN training

- Generator 와 Discriminator 의 모든 가중치는 적대적 훈련을 수행하여 미세 조정 실시
- Class conditional latent vector generator로 latent vectors z_c 를 생성하고 G를 통해 가짜 이미지들을 생성
- D_d 는 진짜 이미지와 가짜 이미지를 n개의 클래스 중 하나 또는 가짜를 구분하여 분류하며 학습
- G 는 가짜 이미지를 생성할 때 사용된 Class label c와 D_d 가 분류한 label 일치하도록 학습



Experiments

❖ Data

- MNIST, CIFAR-10, Flowers, GTSRB

Dataset name	Resolution	Classes	Training images per class			
			Min	Median	Mean	Max
<i>MNIST</i>	28×28	10	5421	5936	6000	6742
<i>CIFAR-10</i>	32×32	10	5000	5000	5000	5000
<i>Flowers</i>	224×224	5	533	599	634	798
<i>GTSRB</i>	64×64	43	210	600	911	2250

- MNIST, CIFAR-10, Flowers는 균형 데이터이기 때문에 불균형하게 데이터를 변형 실시
 - 데이터의 한 클래스를 선택하고 해당 클래스의 인스턴스의 일정 퍼센트를 삭제하여 불균형데이터 생성
- GTSRB 는 불균형 데이터이기 때문에 변형 없이 사용

Experiments

❖ Performance Evaluation

- BAGAN과 ACGAN은 소수 클래스와 다수 클래스 데이터 모두 사용하여 학습하고 소수 데이터 생성
- GAN은 소수 클래스 데이터로만 학습하고 소수 데이터 생성



소수 클래스 이미지를
정상적으로 생성

소수 클래스 이미지를
정상적으로
생성하지 못함

Mode collapse
현상 발생

Experiments

❖ Performance Evaluation

- BAGAN과 ACGAN은 소수 클래스와 다수 클래스 데이터 모두 사용하여 학습하고 소수 데이터 생성
- GAN은 소수 클래스 데이터로만 학습하고 소수 데이터 생성



(a) Real image samples



(b) BAGAN

소수 클래스 이미지를
정상적으로 생성



(c) ACGAN

소수 클래스 이미지를
정상적으로
생성하지 못함



(d) Simple GAN


Mode collapse
현상 발생

Experiments

❖ Performance Evaluation

◆ 생성된 이미지의 정확도

- ResNet-18 모델을 원본데이터로 학습을 실시 후 생성된 소수 클래스 데이터 classification 실시
- BAGAN으로 생성된 데이터는 GAN, ACGAN으로 생성된 데이터 보다 높은 정확도로 분류 됨을 확인




Experiments

❖ Performance Evaluation

◆ 생성된 이미지의 가변성


- SSIM(Structural image similarity)을 사용하여 두 이미지 간의 유사도를 측정
 - SSIM : 이미지의 밝기, 대비, 구조 등을 고려하여 이미지 유사성을 계산
0~1 사이의 값으로 나타나며, 1에 가까울 수록 유사함을 나타냄
- BAGAN으로 생성된 데이터는 GAN, ACGAN으로 생성된 데이터 보다 가변적임




Experiments

❖ Performance Evaluation

◆ 증강 데이터 세트에 대한 Classification 정확도



- BAGAN은 ACGAN 및 GAN과 비교했을 때 높은 Classification 정확도를 보여줌
- 이미지 방향에 민감한 특징이 있는 경우 (MNIST, GTSRB) Mirror 방식은 Worst한 결과를 보여줌



Summarization

❖ Conclusion

- GAN을 사용하여 불균형한 데이터 세트의 균형을 회복하는 BAGAN 방법론을 제시
- BAGAN의 Generator(G)와 Discriminator(D_d)는 Autoencoder의 가중치로 초기화 되어 좋은 Solution으로부터 적대적 학습을 시작하며 Latent vector에서 서로 다른 클래스가 어떻게 표현되어야 하는지를 학습
- BAGAN으로 균형이 회복된 증강 데이터 세트로 Classification을 실시하여 소수 클래스 데이터 분류 정확도가 높아짐을 확인

Generative Adversarial Network for imbalanced data

Paper

❖ IDA-GAN: A Novel Imbalanced Data Augmentation GAN

- Yang, Hao, and Yun Zhou. "Ida-gan: A novel imbalanced data augmentation gan." 2020 25th International Conference on Pattern Recognition (ICPR). IEEE, 2021.

2020 25th International Conference on Pattern Recognition (ICPR)
Milan, Italy, Jan 10-15, 2021

IDA-GAN: A Novel Imbalanced Data Augmentation GAN

Hao Yang, Yun Zhou

Science and Technology on Information Systems Engineering Laboratory
National University of Defense Technology, Changsha, Hunan, P.R. China
Email: zhouyun@nudt.edu.cn


Abstract—Class imbalance is a widely existed and challenging problem in real-world applications such as disease diagnosis, fraud detection, network intrusion detection and so on. Due to the scarce of data, it could significantly deteriorate the accuracy of classification. To address this challenge, we propose a novel Imbalanced Data Augmentation Generative Adversarial Networks (GAN) named IDA-GAN as an augmentation tool to deal with the imbalanced dataset. This is a great challenge

achieves balance mainly by adding minority-class samples. However, traditional data augmentation usually apply some geometric changes on the image classification dataset, e.g. rotation, scaling, translation or mirroring [6] [7], and it might disrupt original relevant features. To address this problem, we introduce an improved GAN model named IDA-GAN in this paper.

IDA-GAN: A Novel Imbalanced Data Augmentation GAN

❖ BAGAN 의 한계

- BAGAN은 Autoencoder(AE)로 Class의 분포를 추론
 - 입력데이터를 단순 Mapping 하는 것에 불과함
 - AE는 입력이 조금만 변해도 출력이 달라질 수 있음
 - 학습된 분포는 Class의 Boundary를 제대로 포착할 수 없음




Autoencoder 구조

IDA-GAN: A Novel Imbalanced Data Augmentation GAN

❖ BAGAN 의 한계

- Generator(G)가 최적화 된다면
 - 생성된 샘플이 클래스 레이블과 연관될 확률이 최대화
 - Discriminator(D_d)가 최적화 된다면
 - 생성된 샘플이 가짜 레이블과 연관될 확률이 최대화
- G와 D_d 가 동시에 최적점 달성 어려움





BAGAN 구조

IDA-GAN: A Novel Imbalanced Data Augmentation GAN

❖ IDA-GAN


- Autoencoder 대신 Variational autoencoder(VAE) 를 통하여 Latent vector 분포 추론
 - VAE는 입력 데이터를 Latent space로 Mapping하는 동시에 Latent vector의 분포를 학습
 - 데이터의 특징을 잘 반영하고 다양한 변화에 적응할 수 있는 잠재 변수의 분포를 학습
 - VAE는 소수 클래스에 대한 Latent vector를 보다 정확하게 생성
 - 이후 학습될 GAN의 G 가 더욱 다양하고 품질이 높은 샘플을 생성할 수 있도록 해줌



IDA-GAN: A Novel Imbalanced Data Augmentation GAN

❖ IDA-GAN

- VAE의 가중치를 사용하여 GAN 초기화를 실시(BAGAN과 동일)
 - IDA-GAN의 Generator는 VAE의 D로 초기화, Discriminator는 VAE의 E로 초기화
- Generator 입력은 Latent vector와 Class로 구성
- Discriminator 는 Real/Fake 을 구별하고 Class label과 연결하는 것을 목표로 함



IDA-GAN 구조

✓ ACGAN의 구조

ACGAN과 달리 **VAE를 적용**하여 이미 소수 클래스 manifold를 안정화 하여, 모든 클래스 분포를 얻었기 때문에 GAN을 통해 불균형한 데이터에서도 고품질의 소수 샘플을 생성할 수 있음

Experiments

❖ Data

- MNIST, Fashion-MNIST, CIFAR-10, SVHN, GTSRB
- MNIST, Fashion-MNIST, CIFAR-10, SVHN는 균형 데이터이기 때문에 불균형하게 데이터를 변형 실시
 - 클래스에서 크기가 다른 샘플을 무작위로 선택하여 불균형한 데이터 세트를 구성
- GTSRB 는 불균형 데이터이기 때문에 변형 없이 사용


TABLE I
THE DETAILS OF THE EXPERIMENTAL DATASETS.

Dataset name	Shape	Classes	Training set	Testing set
MNIST	28 x 28 x 1	10	{4000,2000,1000,750, 500,350,200,100,60,40}	{980,1135,1032,1010,982 892,958,1028,974,1009}
Fashion-MNIST	28 x 28 x 1	10	{4000,2000,1000,750, 500,350,200,100,60,40}	{1000,1000,1000,1000,1000 1000,1000,1000,1000,1000}
SVHN	32 x 32 x 3	10	{4500,2000,1000,800, 600,500,400,250,150,80}	{1744,5099,4149,2882,2523 2384,1977,2019,1660,1595}
CIFAR-10	32 x 32 x 3	10	{4500,2000,1000,800, 600,500,400,250,100,80}	{1014,1012,1023,1012,991 1016,1005,1015,965,947}
GTSRB	32 x 32 x 3	43	{2250,2220,2160,2100, ...,240,240,210,210,210}	{750,720,720,690,690 ...,60,60,60,60}

Experiments

❖ Performance Evaluation

◆ 생성 데이터 분석




ACGAN은 가방의 분포를
포착하지 못함
→ 3,5번째 열과 유사한
이미지 생성

BAGAN은 전체적으로
IDA-GAN보다 흐릿하며
이미지가 불완전함

Experiments

❖ Performance Evaluation

◆ 생성 데이터 분석



ACGAN은 셔츠의 분포를
포착하지 못함
→ 7번째 셔츠 Class에는
6번째 샌들이 포함됨

BAGAN은 전체적으로
IDA-GAN보다 흐릿하며
이미지가 불완전함

Experiments

❖ Performance Evaluation

◆ 분류 성능 비교

- 1 Channel 데이터 세트 분류 성능 비교

Method	MNIST			Fashion-MNIST		
	Precision(%)	Recall(%)	F1(%)	Precision(%)	Recall(%)	F1(%)
ACGAN	86.34	81.10	78.90	77.15	67.45	66.31
BAGAN	87.09	82.73	80.86	80.28	70.71	69.69
IDA-GAN	88.45	83.25	82.56	83.33	79.72	78.85

- 3 Channel 데이터 세트 분류 성능 비교

Method	SVHN			CIFAR-10			GTSRB		
	Precision (%)	Recall(%)	F1(%)	Precision(%)	Recall(%)	F1(%)	Precision(%)	Recall(%)	F1(%)
ACGAN	71.93	54.80	55.39	64.31	51.58	48.99	83.04	83.08	81.72
BAGAN	77.55	73.94	72.39	69.42	67.82	61.65	85.55	85.60	84.46
IDA-GAN	79.32	75.59	74.44	73.77	66.01	64.36	87.20	87.53	86.41

Summarization

❖ Conclusion

- BAGAN에서 autoencoder로 초기화 할 때 발생하는 한계와 Discriminator구조로 인해 발생하는 모순적 한계를 극복한 IDA-GAN 방법론을 제시
- BAGAN의 Discriminator 구조를 ACGAN구조로 변경하여 다양하고 고품질의 이미지를 생성
- IDA-GAN는 Autoencoder 대신 Variational autoencoder(VAE)을 사용해서 데이터의 특징을 잘 반영하고 다양한 변화에 적응할 수 있는 잠재 변수의 분포를 학습
- IDA-GAN을 VAE의 가중치로 초기화 하여 GAN의 Generator가 더욱 다양하고 높은 품질의 샘플을 생성할 수 있게 됨
- IDA-GAN으로 데이터 증강 시 ACGAN, BAGAN으로 증강하였을 때 보다 분류 성능이 높음을 실험적으로 확인

Generative Adversarial Network for imbalanced data

Paper

❖ Enhanced balancing GAN: minority-class image generation

- Huang, Gaofeng, and Amir Hossein Jafari. "Enhanced balancing GAN: Minority-class image generation." Neural computing and applications 35.7 (2023): 5145-5154.

Enhanced balancing GAN: minority-class image generation

Gaofeng Huang¹  • Amir Hossein Jafari¹

Received: 26 August 2020 / Accepted: 24 May 2021 / Published online: 17 June 2021
© The Author(s), under exclusive licence to Springer-Verlag London Ltd., part of Springer Nature 2021

Abstract


Generative adversarial networks (GANs) are one of the most powerful generative models, but always require a large and balanced dataset to train. Traditional GANs are not applicable to generate minority-class images in a highly imbalanced dataset. Balancing GAN (BAGAN) is proposed to mitigate this problem, but it is unstable when images in different classes look similar, e.g., flowers and cells. In this work, we propose a supervised autoencoder with an intermediate embedding model to disperse the labeled latent vectors. With the enhanced autoencoder initialization, we also build an architecture of BAGAN with gradient penalty (BAGAN-GP). Our proposed model overcomes the unstable issue in original BAGAN and converges faster to high-quality generations. Our model achieves high performance on the imbalanced scale-down version of MNIST Fashion, CIFAR-10, and one small-scale medical image dataset. <https://github.com/GH920/improved-bagan-gp>.

Keywords GAN · Imbalanced data · Image generation · Data augmentation · Medical image


Enhanced balancing GAN: minority-class image generation

❖ BAPAN 의 한계

- BAPAN은 유사한 클래스가 많은 경우 성능이 불안정함
 - Flowers 데이터 셋의 경우 유사한 클래스가 많기 때문에 BAPAN의 성능이 좋지 않음을 확인
- 의료 이미지 데이터 세트에서는 BAPAN 성능이 불안정
 - 드문 병리학적 사례로 인하여 매우 불균형적인 데이터
 - 클래스 간 차이를 구분하기 어려움



BAPAN으로 생성된 데이터 분류 성능




BAPAN으로 생성된 의료 이미지

Enhanced balancing GAN: minority-class image generation

❖ BAGAN 의 한계


- Autoencoder(AE)로 생성한 서로 다른 Class의 Latent vector 분포 간에 중첩이 있을 수 있음
 - 중첩된 분포(즉, Label 정보가 불명확한 분포)에 의해 이후 GAN 훈련에 오해를 일으킬 수 있음
 - Latent vector가 완벽하게 분산되어 있더라도 훈련된 Decoder(D)에만 적합할 수 있음
 - GAN 모델을 훈련할 때 Labeled latent vector 의 분포를 더 이상 업데이트할 수 없음
 - ✓ Embedding 작업을 도입



Enhanced balancing GAN: minority-class image generation

❖ BAGAN-GP

- BAGAN과 동일하게 AE 를 사용하여 Latent vector 분포를 파악
- BAGAN과 차이점은 Supervised learning 으로 AE 학습
- Label 정보를 포함하기 위해 Latent vector 와 Label을 함께 Embedding(multiply layer) 작업을 거쳐 Labeled latent vector로 변환




Autoencoder with an intermediate embedding model

Enhanced balancing GAN: minority-class image generation

❖ BAGAN-GP

- BAGAN-GP의 Generator는 AE 로 사전 학습된 Embedding 모델과 Decoder(D) 의 집합 모델
- 임의의 Latent vector 와 임의의 Label을 입력하면 특정 Class의 이미지를 생성
- Generator 내부의 Embedding 모델은 GAN 훈련으로 추가적인 업데이트 실시 가능




BAGAN-GP 구조

Enhanced balancing GAN: minority-class image generation

❖ BAGAN-GP


- BAGAN-GP의 Discriminator는 cWGAN-GP(conditional WassersteinGAN-Gradient Penalty)와 유사
 - 모델의 안정성을 개선



Enhanced balancing GAN: minority-class image generation

❖ BAGAN-GP

- BAGAN-GP의 Discriminator는 cWGAN-GP(conditional WassersteinGAN-Gradient Penalty)와 유사
- WGAN(WassersteinGAN)
 - Wasserstein 거리를 이용하여 안정적인 학습을 진행
 - Wasserstein 거리: 생성된 데이터 분포와 실제 데이터 분포 간의 거리를 최소화하는 방식




- 실제 데이터 분포와 생성 데이터 분포가 떨어져 있을 경우
- 기존 GAN의 경우 Discriminator의 출력
 - 실제 데이터 분포에서는 1, 생성 데이터 분포에서는 0 만을 출력
 - Vanishing Gradient가 발생
- WGAN의 경우 분포의 거리를 측정하므로 Gradient가 선형적으로 됨
 - 지속적인 미분 가능으로 생성 데이터 분포가 실제 데이터 분포로 이동됨


Enhanced balancing GAN: minority-class image generation

❖ BAKAN-GP

- BAKAN-GP의 Discriminator는 cWGAN-GP(conditional WassersteinGAN-Gradient Penalty)와 유사
- GP(Gradient Penalty)
 - 실제 이미지와 생성된 이미지 사이의 중간 지점에서 Gradient를 계산하고, 이를 활용하여 Discriminator의 Gradient를 조절
 - 중간 지점에서 Sampling한 이미지는 Gradient 계산에 실제 이미지와 생성된 이미지의 특징을 모두 반영
 - 중간 지점에서의 Gradient의 크기를 측정하고, 이 크기가 일정 범위를 벗어나지 않도록 Penalty를 부여
 - 가중치가 경계로 몰리는 경향을 완화



→ Weight Clipping의 경우
Weight가 Boundary에
몰리는 문제가 발생




→ Gradient Penalty의 경우
Weight가 Boundary에
몰리는 문제를 완화

Enhanced balancing GAN: minority-class image generation

❖ BAGAN-GP


- BAGAN-GP의 Discriminator는 cWGAN-GP(conditional WassersteinGAN-Gradient Penalty)와 유사
 - 모델의 안정성을 개선
 - 생성된 데이터 분포와 실제 데이터 분포 사이의 거리를 최소화하는 방향으로 Generator를 학습



Enhanced balancing GAN: minority-class image generation

❖ BAKAN-GP

- Discriminator는 Label 과 이미지 데이터 입력을 조합하여 Real/Fake 판별을 수행
 - Embedding layer(Random하게 초기화)는 Label 정보를 Embedding vector(Embedded labels)로 변환하는 역할
 - AE 로 사전 학습된 Encoder(E)로 초기화 되며 이미지를 Feature map 으로 변환
 - Embedded labels 과 Feature map을 결합하여 새로운 Dense vector 생성
- Discriminator의 출력 값으로 유효성(Validity)을 나타내는 값으로 해석
 - 주어진 입력이 실제 데이터일 확률을 나타내는 실수 범위로 해석
(출력 값이 0에 가까울수록 가짜 데이터일 확률이 높고, 1에 가까울수록 실제 데이터일 확률이 높다고 해석)



Experiments

❖ Data

- Fashion-MNIST, CIFAR-10, Medical image dataset: cells
- CIFAR-10, Fashion-MNIST는 균형 데이터이기 때문에 불균형하게 데이터를 변형 실시
 - A,C는 균형적 상태 / B,D는 변형한 불균형 상태

	T-shirt	Trouser	Pullover	Dress	Coat	Sandal	Shirt	Sneaker	Bag	Boot
A	4231	4165	4199	4211	4185	4217	4189	4241	4175	4187
B	4166	73	139	210	287	370	422	387	545	651
	Airplane	Automobile	Bird	Cat	Deer	Dog	Frog	Horse	Ship	Truck
C	3527	3523	3500	3458	3563	3455	3535	3509	3453	3476
D	3490	71	130	221	269	349	435	485	572	628

Fashion-MNIST


CIFAR-10

Experiments

❖ Data

- Fashion-MNIST, CIFAR-10, Medical image dataset: cells
- Medical image dataset: cells 는 불균형 데이터
 - 다수 클래스 1개, 소수 클래스 3개
 - 특정 특징에서 일부가 다르지만 시각적으로 유사하며 특히 Type 2 와 Type 3 세포를 구별하기는 어려움

	Normal (type 0)	Ring (type 1)	Schizont (type 2)	Trophozoite (type 3)
Train	5600	292	106	887
Test	1400	73	27	222



Experiments

❖ Performance Evaluation

◆ 생성 이미지 비교

- Fashion-MNIST 균형 데이터 세트와 불균형 데이터 세트 생성 이미지 비교



Train on the balanced version (A)

Train on a highly imbalanced version (B)


- 불균형한 데이터 세트에서도 생성 이미지가 완벽하게 생성
- 불균형 데이터 셋(B)의 경우에도 소수 클래스의 열을 쉽게 파악할 수 없음

Experiments

❖ Performance Evaluation

◆ 생성 이미지 비교

- CIFAR-10 균형 데이터 세트와 불균형 데이터 세트 생성 이미지 비교



Train on the balanced version (C)

Train on a highly imbalanced version (D)


- 불균형한 데이터 세트에서도 생성 이미지가 완벽하게 생성
- 불균형 데이터 셋(D)의 경우에도 소수 클래스의 열을 쉽게 파악할 수 없음

Experiments

❖ Performance Evaluation

◆ 생성 이미지 비교

- cells 불균형 데이터 세트 생성 이미지



➤ BAGAN-GP를 사용하면 모든 유형의 세포를 고품질로 생성





Experiments

❖ Performance Evaluation


◆ cells data latent vector t-SNE 분포 비교

- Encoded latent vector 2차원 t-SNE Plot

t-SNE: 고차원 데이터를 시각화하기 위해 사용되는 비선형 차원 축소 기법
데이터 포인트의 유사도를 고려하여 저차원 공간에 매핑



BAGAN



BAGAN-GP

A BAGAN의 Encoder는 입력 이미지를 분산된 Latent vector 그룹으로 변환하지 못함

↓
잘못된 Class 별 Latent vector 발생

↓
잘못된 이미지 생성 가능성 발생

C BAGAN-GP의 경우 Embedding을 통해 분산된 Latent vector 그룹 변환 가능
(B: Embedding 적용 전
→ C: Embedding 적용 후)


↓
안정된 Class 별 Latent vector 발생

Experiments

❖ Performance Evaluation

◆ cells data feature layer output t-SNE 분포 비교

- ResNet-50을 사용하여 Feature layer output에 의한 실제 Sample(o)과 생성된 Sample(x) 비교



- 생성된 이미지 manifold가 실제 이미지 manifold 주변에 골고루 분포
- 생성된 샘플들이 효과적인 증강 이미지로 간주될 수 있음을 의미

Experiments

❖ Performance Evaluation

◆ cells data FID score 비교

- 모델에 따른 FID score 비교

✓ FID(Frechet Inception Distance) score:

생성된 이미지와 실제 이미지 간 특징의 통계적 유사성을 계산하여 두 이미지 분포 사이의 차이를 측정 (낮은 score는 생성된 이미지가 실제 이미지와 유사하다는 것을 의미)


	Type0 (1400 samples)	Type1 (73 samples)	Type2 (27 samples)	Type3 (222 samples)
Rec. samples (Autoencoder)	132.715	247.174	322.567	240.519
BAGAN	197.961	213.705	278.755	184.903
cDRAGAN	90.981	184.440	233.512	155.564
BAGAN-GP (v1)	77.831	211.698	227.366	168.240
BAGAN-GP (v2)	97.445	152.986	213.864	141.798
BAGAN-GP (v3, 100)	100.151	143.703	195.926	112.875
BAGAN-GP (v3, 200)	88.562	147.994	194.544	115.881
Real samples (Train)	20.498	93.721	127.392	58.048

*The top two scores are decorated with bold style

➤ v1,v2 : Embedding 없는 모델

▪ v1 : 실제 Label 사용

▪ v2 : 실제 Label / 생성 Label 사용



Experiments

❖ Performance Evaluation

◆ cells data FID score 비교

- 모델에 따른 FID score 비교

✓ FID(Frechet Inception Distance) score:

생성된 이미지와 실제 이미지 간의 특징 통계적 유사성을 계산하여 두 이미지 분포 사이의 차이를 측정 (낮은 score는 생성된 이미지가 실제 이미지와 유사하다는 것을 의미)


	Type0 (1400 samples)	Type1 (73 samples)	Type2 (27 samples)	Type3 (222 samples)
Rec. samples (Autoencoder)	132.715	247.174	322.567	240.519
BAGAN	197.961	213.705	278.755	184.903
cDRAGAN	90.981	184.440	233.512	155.564
BAGAN-GP (v1)	77.831	211.698	227.366	168.240
BAGAN-GP (v2)	97.445	152.986	213.864	141.798
BAGAN-GP (v3, 100)	100.151	143.703	195.926	112.875
BAGAN-GP (v3, 200)	88.562	147.994	194.544	115.881
Real samples (Train)	20.498	93.721	127.392	58.048

*The top two scores are decorated with bold style

➤ v1,v2 : Embedding 없는 모델

▪ v1 : 실제 Label 사용

▪ v2 : 실제 Label / 생성 Label 사용



Experiments

❖ Performance Evaluation

◆ cells data FID score 비교

- 모델에 따른 FID score 비교

✓ FID(Frechet Inception Distance) score:

생성된 이미지와 실제 이미지 간의 특징 통계적 유사성을 계산하여 두 이미지 분포 사이의 차이를 측정 (낮은 score는 생성된 이미지가 실제 이미지와 유사하다는 것을 의미)

	Type0 (1400 samples)	Type1 (73 samples)	Type2 (27 samples)	Type3 (222 samples)
Rec. samples (Autoencoder)	132.715	247.174	322.567	240.519
BAGAN	197.961	213.705	278.755	184.903
cDRAGAN	90.981	184.440	233.512	155.564
BAGAN-GP (v1)	77.831	211.698	227.366	168.240
BAGAN-GP (v2)	97.445	152.986	213.864	141.798
BAGAN-GP (v3, 100)	100.151	143.703	195.926	112.875
BAGAN-GP (v3, 200)	88.562	147.994	194.544	115.881
Real samples (Train)	20.498	93.721	127.392	58.048

*The top two scores are decorated with bold style

➤ v1,v2 : Embedding 없는 모델

- v1 : 실제 Label 사용

- v2 : 실제 Label / 생성 Label 사용

➤ V1의 경우

- 불균형한 데이터 세트에서 무작위로 Sampling된 실제 Label도 여전히 불균형

- GAN이 다수 클래스에 치중하여 학습

Experiments

❖ Performance Evaluation

◆ cells data FID score 비교

- 모델에 따른 FID score 비교

✓ FID(Frechet Inception Distance) score:

생성된 이미지와 실제 이미지 간의 특징 통계적 유사성을 계산하여 두 이미지 분포 사이의 차이를 측정 (낮은 score는 생성된 이미지가 실제 이미지와 유사하다는 것을 의미)

	Type0 (1400 samples)	Type1 (73 samples)	Type2 (27 samples)	Type3 (222 samples)
Rec. samples (Autoencoder)	132.715	247.174	322.567	240.519
BAGAN	197.961	213.705	278.755	184.903
cDRAGAN	90.981	184.440	233.512	155.564
BAGAN-GP (v1)	77.831	211.698	227.366	168.240
BAGAN-GP (v2)	97.445	152.986	213.864	141.798
BAGAN-GP (v3, 100)	100.151	143.703	195.926	112.875
BAGAN-GP (v3, 200)	88.562	147.994	194.544	115.881
Real samples (Train)	20.498	93.721	127.392	58.048

*The top two scores are decorated with bold style

➤ v1,v2 : Embedding 없는 모델

- v1 : 실제 Label 사용

- v2 : 실제 Label / 생성 Label 사용

➤ V2의 경우

- 가짜 이미지에 대한 Label 세트에서 Sampling 실시

- 소수 클래스 생성 개선 효과

Experiments

❖ Performance Evaluation

◆ cells data FID score 비교

- 모델에 따른 FID score 비교

✓ FID(Frechet Inception Distance) score:


생성된 이미지와 실제 이미지 간의 특징 통계적 유사성을 계산하여 두 이미지 분포 사이의 차이를 측정 (낮은 score는 생성된 이미지가 실제 이미지와 유사하다는 것을 의미)

	Type0 (1400 samples)	Type1 (73 samples)	Type2 (27 samples)	Type3 (222 samples)
Rec. samples (Autoencoder)	132.715	247.174	322.567	240.519
BAGAN	197.961	213.705	278.755	184.903
cDRAGAN	90.981	184.440	233.512	155.564
BAGAN-GP (v1)	77.831	211.698	227.366	168.240
BAGAN-GP (v2)	97.445	152.986	213.864	141.798
BAGAN-GP (v3, 100)	100.151	143.703	195.926	112.875
BAGAN-GP (v3, 200)	88.562	147.994	194.544	115.881
Real samples (Train)	20.498	93.721	127.392	58.048

*The top two scores are decorated with bold style

➤ v3 : Embedding 있는 모델

▪ 200 epochs 까지 학습 평가



➤ 기존 GAN들은 훈련 시간이 길어지면 수렴에 실패하는 경향들이 있으나 GP를 통해 긴 훈련 동안에도 안정적으로 학습

Summarization

❖ Conclusion

- BAGAN이 유사한 클래스의 데이터 생성에는 한계점 존재
- BAGAN의 autoencoder를 Supervised autoencoder로 변경
 - 정보를 직접 학습하는 Embedding을 추가 하여 Class간의 분산을 안정화 시킴
- cWGAN-GP의 방법을 적용하여 더욱 안정적으로 학습할 수 있는 BAGAN-GP를 제안
- BAGAN-GP는 의료 이미지 데이터 세트와 같이 유사한 클래스가 많은 데이터의 경우에도 고품질의 소수 클래스를 생성할 수 있음

Conclusion

- ❖ 실제 세계의 많은 불균형 데이터가 존재하며 이는 Deep learning 성능에 부정적인 영향을 미침
- ❖ 불균형데이터를 입력으로 사용하여 GAN을 통해 데이터를 증강하는 기법을 소개(BAGAN, IDA-GAN, BAGAN-GP)
- ❖ BAGAN
 - Autoencoder를 사용하여 GAN을 초기화하고, Latent space에서 Class를 Encoding하는 방법을 학습
 - 이를 통해 BAGAN은 소수 클래스의 특징을 학습하고, 소수 클래스에 대한 이미지를 생성할 수 있음
- ❖ IDA-GAN
 - BAGAN을 개선한 방법론으로 Variational autoencoder로 GAN을 초기화하고 discriminator 출력 구조를 변경하여 소수 클래스 데이터를 BAGAN보다 안정적으로 생성할 수 있음
- ❖ BAGAN-GP
 - BAGAN을 개선한 방법론으로 중간 Embedding 모델을 사용하며, 이를 통해 유사하지만 다른 클래스의 이미지를 분산시키는 Label 정보를 학습
 - Generator는 Label 정보를 이용하여 불균형 데이터셋에서 소수 클래스 생성을 다룰 수 있으며, 의료데이터와 같은 유사한 클래스가 많은 데이터의 경우에 BAGAN 보다 높은 성능으로 이미지를 생성할 수 있음
 - WGAN-GP의 구조를 사용하여 GAN의 학습이 안정적으로 이루어지도록 개선

감사합니다