



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2025-0104121
(43) 공개일자 2025년07월08일

(51) 국제특허분류(Int. Cl.)
G06N 3/0475 (2023.01)

(52) CPC특허분류
G06N 3/0475 (2023.01)

(21) 출원번호 10-2023-0196187

(22) 출원일자 2023년12월29일

심사청구일자 2023년12월29일

(71) 출원인

울산과학기술원

울산광역시 울주군 언양읍 유니스트길 50

(72) 발명자

유재준

울산광역시 울주군 언양읍 유니스트길 50

김범준

울산광역시 울주군 언양읍 유니스트길 50

(뒷면에 계속)

(74) 대리인

특허법인비엘터


전체 청구항 수 : 총 10 항

(54) 발명의 명칭 생성 모델의 품질 및 다양성을 평가하는 생성 모델 평가 장치 및 이를 이용한 생성 모델 평가 방법

(57) 요약

본 개시의 생성 모델의 품질 및 다양성을 평가하는 생성 모델 평가 장치는 입력 데이터를 수치화된 특징 벡터로 변환하는 특징 임베딩부, 상기 특징 벡터에 기초하여 데이터 분포를 추정하는 확률 분포 추정부, 컨피던스 밴드를 추정하는 컨피던스 밴드 추정부, 및 TopP 및 TopR에 기초하여 생성 모델을 평가하는 평가부를 포함할 수 있다. 상기 평가부는 품질(Fidelity) 및 다양성(Diversity) 측면에서 위상적이면서도 통계적으로 생성 모델을 평가할 수 있다.

대표도 - 도1



(72) 발명자

장유진

울산광역시 울주군 언양읍 유니스트길 50

김지수

서울시 도봉구 방학로 15길 40 신동아아파트 103동
309호

이 발명을 지원한 국가연구개발사업

과제고유번호 1711193127
 과제번호 2022-0-00959-002
 부처명 과학기술정보통신부
 과제관리(전문)기관명 정보통신기획평가원
 연구사업명 사람중심인공지능핵심원천기술개발
 연구과제명 (2세부) 의사결정 지원을 위한 퓨샷 학습 기반 시각 및 언어에 대한 인과관계 추론

기술개발

기 여 율 40/100
 과제수행기관명 서울대학교 산학협력단
 연구기간 2023.01.01 ~ 2023.12.31

이 발명을 지원한 국가연구개발사업

과제고유번호 1711189018
 과제번호 2022R1C1C1008496
 부처명 과학기술정보통신부
 과제관리(전문)기관명 한국연구재단
 연구사업명 개인기초연구(과기정통부)
 연구과제명 강력하고 해석 가능한 딥러닝 생성 모델을 위한 신호처리 기반 분석 도구 및 학습

알고리즘 개발: 일반, 바이오, 의료 영상으로의 응용

기 여 율 40/100
 과제수행기관명 울산과학기술원
 연구기간 2023.03.01 ~ 2024.02.29

이 발명을 지원한 국가연구개발사업

과제고유번호 1711193397
 과제번호 2022-0-00264-002
 부처명 과학기술정보통신부
 과제관리(전문)기관명 정보통신기획평가원
 연구사업명 사람중심인공지능핵심원천기술개발
 연구과제명 지식기반 심층논리 신경망을 활용한 통합적 비디오 해석과 생성 연구
 기 여 율 10/100
 과제수행기관명 한양대학교산학협력단
 연구기간 2023.01.01 ~ 2023.12.31

이 발명을 지원한 국가연구개발사업

과제고유번호 1711193622
 과제번호 2021-0-02068-003
 부처명 과학기술정보통신부
 과제관리(전문)기관명 정보통신기획평가원
 연구사업명 정보통신방송혁신인재양성
 연구과제명 인공지능 혁신 허브 연구 개발
 기 여 율 5/100
 과제수행기관명 고려대학교산학협력단
 연구기간 2023.01.01 ~ 2023.12.31

이 발명을 지원한 국가연구개발사업

과제고유번호 1711193983
 과제번호 2020-0-01336-004
 부처명 과학기술정보통신부
 과제관리(전문)기관명 정보통신기획평가원
 연구사업명 정보통신방송혁신인재양성
 연구과제명 인공지능대학원지원(울산과학기술원)
 기 여 율 5/100
 과제수행기관명 울산과학기술원
 연구기간 2023.01.01 ~ 2023.12.31

명세서

청구범위

청구항 1

생성 모델의 품질 및 다양성을 평가하는 생성 모델 평가 장치에 있어서,
입력 데이터를 수치화된 특징 벡터로 변환하는 특징 임베딩부;
상기 특징 벡터에 기초하여 데이터 분포를 추정하는 확률 분포 추정부;
컨피던스 밴드를 추정하는 컨피던스 밴드 추정부; 및
TopP 및 TopR에 기초하여 생성 모델을 평가하는 평가부를 포함하고,
상기 평가부는,
품질(Fidelity) 및 다양성(Diversity) 측면에서 위상적이면서도 통계적으로 생성 모델을 평가하는,
생성 모델 평가 장치.

청구항 2

제1항에 있어서,
상기 확률 분포 추정부는,
토폴로지컬 데이터 분석(Topological Data Analysis)의 지속적 호몰로지(persistent homology)를 기반으로 데이터의 실제 신호(real signal)만을 이용하여 상기 데이터 분포를 추정하는,
생성 모델 평가 장치.

청구항 3

제1항에 있어서,
상기 컨피던스 밴드 추정부는,
아웃라이어, IID Perturbation, 및 Non-IID Perturbation 중 적어도 하나를 포함하는 노이즈가 포함된 이미지 데이터셋의 분포를 근사할 때, 새롭게 정의한 신뢰 구간에 기초하여 노이즈 시그널(noisy signal)에 대해 강건한 상기 데이터 분포를 추정하는,
생성 모델 평가 장치.

청구항 4

제1항에 있어서,
상기 평가부는,
추정된 데이터 분포에 기초하여 이미지의 품질 및 다양성을 평가하고,
복수의 임베딩 공간(embedding space)에서 일관적인 평가를 제시하는 평가 매트릭을 제공하는,
생성 모델 평가 장치.

청구항 5

제1항에 있어서,
상기 평가부는,
IS 및 FID 중 적어도 하나를 포함하는 단일 평가 점수를 통해 상기 생성 모델의 성능에 기초하여 상기 생성 모

텔의 순위를 평가하는,
생성 모델 평가 장치.

청구항 6

생성 모델의 품질 및 다양성을 평가하는 생성 모델 평가 방법에 있어서,
입력 데이터를 수치화된 특징 벡터로 변환하는 동작;
상기 특징 벡터에 기초하여 데이터 분포를 추정하는 동작;
컨피던스 밴드를 추정하는 동작; 및
TopP 및 TopR에 기초하여 생성 모델을 평가하는 동작을 포함하고,
상기 생성 모델을 평가하는 동작은,
품질(Fidelity) 및 다양성(Diversity) 측면에서 위상적이면서도 통계적으로 생성 모델을 평가하는,
생성 모델 평가 방법.

청구항 7

제6항에 있어서,
상기 특징 벡터에 기초하여 데이터 분포를 추정하는 동작은,
토폴로지컬 데이터 분석(Topological Data Analysis)의 지속적 호몰로지(persistent homology)를 기반으로 데이터의 실제 신호(real signal)만을 이용하여 상기 데이터 분포를 추정하는,
생성 모델 평가 방법.

청구항 8

제6항에 있어서,
상기 컨피던스 밴드를 추정하는 동작은,
아웃라이어, IID Perturbation, 및 Non-IID Perturbation 중 적어도 하나를 포함하는 노이즈가 포함된 이미지 데이터셋의 분포를 근사할 때, 새롭게 정의한 신뢰 구간에 기초하여 노이즈 시그널(noisy signal)에 대해 강건한 상기 데이터 분포를 추정하는,
생성 모델 평가 방법.

청구항 9

제6항에 있어서,
상기 생성 모델을 평가하는 동작은,
추정된 데이터 분포에 기초하여 이미지의 품질 및 다양성을 평가하고,
복수의 임베딩 공간(embedding space)에서 일관적인 평가를 제시하는 평가 매트릭을 제공하는,
생성 모델 평가 방법.

청구항 10

제6항에 있어서,
상기 생성 모델을 평가하는 동작은,
IS 및 FID 중 적어도 하나를 포함하는 단일 평가 점수를 통해 상기 생성 모델의 성능에 기초하여 상기 생성 모델의 순위를 평가하는,
생성 모델 평가 방법.

발명의 설명

기술 분야

[0001] 본 개시는 생성 모델의 평가 기술에 관한 것으로, 보다 상세하게는 인공지능 기반 생성 모델을 품질, 다양성 측면에서 위상적이면서 통계적으로 평가할 수 있는 매트릭 프로그램을 이용하는 생성 모델 평가 장치 및 이를 이용한 생성 모델 평가 방법에 관한 것이다.

배경 기술

[0002] 최근까지 많은 생성 모델이 연구되어 왔으며, 이에 발맞춰 생성 모델의 성능을 평가하는 방법도 다양하게 제안되었다. 매트릭 중에서 현재 생성 모델을 평가하는데 가장 많이 사용되고 있는 평가지표는 Inception Score(IS), Frechet Inception Distance(FID), Improved Precision and Recall(P&R), Density & Coverage(D&C) 등이 있다.

[0003] 평가 지표들은 공통적으로 특성 공간에서의 이미지 분포를 근사하며, 이러한 데이터 분포를 바탕으로하는 평가 점수를 제시하는 특징을 지닌다. 하지만, IS는 노이즈가 추가된 이미지에 대해서 정확한 평가를 제공하지 못한다는 단점이 있으며, FID는 특성 공간의 데이터 분포를 다변량 정규분포로 가정함으로써 정확한 생성 모델의 성능 평가를 해주지 못한다는 것을 연구를 통해 확인할 수 있다.

[0004] P&R 부류의 매트릭의 경우 아웃라이어(outlier) 혹은 노이즈 데이터(noisy data)에 대한 높은 민감성으로인해 정확한 데이터 분포를 근사하지 못한다는 것을 확인할 수 있다. 대표적으로, P&R 부류의 매트릭은 실제 데이터가 오류(artifact)(예. mislabeling, adversarial example)를 포함하고 있는 경우에 기존 매트릭의 평가 점수는 더욱 신뢰할 수 없다는 문제점이 있다.

[0005] 따라서, 현재 생성 모델의 연구에서는 노이즈 데이터에 대해 강건하며 데이터의 분포에 대한 정확한 근사를 할 수 있는 평가 매트릭이 필요하다.

선행기술문헌

특허문헌

[0006] (특허문헌 0001) 한국공개특허 제10-2023-0159667호 “인공지능 기반 생성적 설계 방법, 장치 및 컴퓨터프로그램”

발명의 내용

해결하려는 과제

[0007] 본 개시의 일 목적은 품질 및 다양성 측면에서 위상적이면서도 통계적으로 생성 모델을 평가할 수 있으며, 종래의 매트릭들보다 더욱 강건하게 생성 모델을 평가함으로써, 생성 모델의 발전에 기여하는 생성 모델 평가 장치를 제공하는 것이다.

[0008] 본 개시의 다른 목적은 품질 및 다양성 측면에서 위상적이면서도 통계적으로 생성 모델을 평가할 수 있으며, 종래의 매트릭들보다 더욱 강건하게 생성 모델을 평가함으로써, 생성 모델의 발전에 기여하는 생성 모델 평가 방법을 제공하는 것이다.

[0009] 다만, 본 개시가 해결하고자 하는 과제들은 이상에서 언급된 과제로 제한되지 않으며, 언급되지 않은 또 다른 과제들은 아래의 기재로부터 통상의 기술자에게 명확하게 이해될 수 있을 것이다.

과제의 해결 수단

[0010] 상술한 기술적 과제를 달성하기 위한 본 개시에 따른 생성 모델의 품질 및 다양성을 평가하는 생성 모델 평가 장치는 입력 데이터를 수치화된 특징 벡터로 변환하는 특징 임베딩부, 상기 특징 벡터에 기초하여 데이터 분포를 추정하는 확률 분포 추정부, 컨피던스 밴드를 추정하는 컨피던스 밴드 추정부, 및 TopP 및 TopR에 기초하여 생성 모델을 평가하는 평가부를 포함할 수 있다. 상기 평가부는 품질(Fidelity) 및 다양성(Diversity) 측면에서

위상적이면서도 통계적으로 생성 모델을 평가할 수 있다.

- [0011] 일 실시예에서, 상기 확률 분포 추정부는 토폴로지컬 데이터 분석(Topological Data Analysis)의 지속적 호몰로지(persistent homology)를 기반으로 데이터의 실제 신호(real signal)만을 이용하여 상기 데이터 분포를 추정할 수 있다.
- [0012] 일 실시예에서, 상기 컨피던스 밴드 추정부는 아웃라이어, IID Perturbation, 및 Non-IID Perturbation 중 적어도 하나를 포함하는 노이즈가 포함된 이미지 데이터셋의 분포를 근사할 때, 새롭게 정의한 신뢰 구간에 기초하여 노이즈 시그널(noisy signal)에 대해 강건한 상기 데이터 분포를 추정할 수 있다.
- [0013] 일 실시예에서, 상기 평가부는 추정된 데이터 분포에 기초하여 이미지의 품질 및 다양성을 평가하고, 복수의 임베딩 공간(embedding space)에서 일관적인 평가를 제시하는 평가 매트릭을 제공할 수 있다.
- [0014] 일 실시예에서, 상기 평가부는 IS 및 FID 중 적어도 하나를 포함하는 단일 평가 점수를 통해 상기 생성 모델의 성능에 기초하여 상기 생성 모델의 순위를 평가할 수 있다.
- [0015] 또한, 본 개시에 따른 생성 모델의 품질 및 다양성을 평가하는 생성 모델 평가 방법은 입력 데이터를 수치화된 특징 벡터로 변환하는 동작, 상기 특징 벡터에 기초하여 데이터 분포를 추정하는 동작, 컨피던스 밴드를 추정하는 동작, 및 TopP 및 TopR에 기초하여 생성 모델을 평가하는 동작을 포함할 수 있다. 상기 생성 모델을 평가하는 동작은 품질(Fidelity) 및 다양성(Diversity) 측면에서 위상적이면서도 통계적으로 생성 모델을 평가할 수 있다.
- [0016] 일 실시예에서, 상기 특징 벡터에 기초하여 데이터 분포를 추정하는 동작은 토폴로지컬 데이터 분석(Topological Data Analysis)의 지속적 호몰로지(persistent homology)를 기반으로 데이터의 실제 신호(real signal)만을 이용하여 상기 데이터 분포를 추정할 수 있다.
- [0017] 일 실시예에서, 상기 컨피던스 밴드를 추정하는 동작은 아웃라이어, IID Perturbation, 및 Non-IID Perturbation 중 적어도 하나를 포함하는 노이즈가 포함된 이미지 데이터셋의 분포를 근사할 때, 새롭게 정의한 신뢰 구간에 기초하여 노이즈 시그널(noisy signal)에 대해 강건한 상기 데이터 분포를 추정할 수 있다.
- [0018] 일 실시예에서, 상기 생성 모델을 평가하는 동작은 추정된 데이터 분포에 기초하여 이미지의 품질 및 다양성을 평가하고, 복수의 임베딩 공간(embedding space)에서 일관적인 평가를 제시하는 평가 매트릭을 제공할 수 있다.
- [0019] 일 실시예에서, 상기 생성 모델을 평가하는 동작은 IS 및 FID 중 적어도 하나를 포함하는 단일 평가 점수를 통해 상기 생성 모델의 성능에 기초하여 상기 생성 모델의 순위를 평가할 수 있다.
- [0020] 이 외에도, 본 개시를 구현하기 위한 컴퓨터 판독 가능한 기록 매체에 저장된 컴퓨터 프로그램이 더 제공될 수 있다.
- [0021] 이 외에도, 본 개시를 구현하기 위한 컴퓨터 프로그램을 기록하는 컴퓨터 판독 가능한 기록 매체가 더 제공될 수 있다.

발명의 효과

- [0022] 본 개시의 기술한 과제 해결 수단에 의하면, 본 개시의 생성 모델 평가 장치 및 이를 이용한 생성 모델 평가 방법은 품질 및 다양성 측면에서 위상적이면서도 통계적으로 생성 모델을 평가할 수 있으며, 종래의 매트릭들보다 더욱 강건하게 생성 모델을 평가함으로써, 생성 모델의 발전에 기여할 수 있다.
- [0023] 본 개시의 효과들은 이상에서 언급된 효과로 제한되지 않으며, 언급되지 않은 또 다른 효과들은 아래의 기재로부터 통상의 기술자에게 명확하게 이해될 수 있을 것이다.

도면의 간단한 설명

- [0024] 도 1은 본 개시의 생성 모델 평가 장치의 구성을 나타내는 블록도이다.
- 도 2는 본 개시의 생성 모델 평가 장치의 동작을 나타내는 순서도이다.
- 도 3은 본 개시의 생성 모델 평가 장치의 컨피던스 밴드의 부스트 스트랩핑을 통한 근사를 나타내는 도면이다.
- 도 4는 본 개시의 생성 모델 평가 장치의 강건한 데이터 분포에 대한 근사를 나타내는 도면이다.

- 도 5는 본 개시의 생성 모델 평가 장치의 단계, TopP&R을 통한 평가 점수 계산을 나타내는 도면이다.
- 도 6은 본 개시의 생성 모델 평가 장치의 컨피던스 밴드 추정부의 제1 알고리즘을 나타내는 도면이다.
- 도 7은 생성된 데이터 분포의 아웃라이어에 대한 평가 매트릭의 평가 경향을 나타내는 도면이다.
- 도 8은 순차적 모드 드롭 및 동시적 모드 드롭이 발생하는 경우 평가 매트릭의 평가 경향을 나타내는 도면이다.
- 도 9는 생성 모델의 순위를 비교하는 도표이다.

발명을 실시하기 위한 구체적인 내용

- [0025] 본 개시 전체에 걸쳐 동일 참조 부호는 동일 구성요소를 지칭한다. 본 개시가 실시예들의 모든 요소들을 설명하는 것은 아니며, 본 개시가 속하는 기술분야에서 일반적인 내용 또는 실시예들 간에 중복되는 내용은 생략한다. 명세서에서 사용되는 '부, 모듈, 부재, 블록'이라는 용어는 소프트웨어 또는 하드웨어로 구현될 수 있으며, 실시예들에 따라 복수의 '부, 모듈, 부재, 블록'이 하나의 구성요소로 구현되거나, 하나의 '부, 모듈, 부재, 블록'이 복수의 구성요소들을 포함하는 것도 가능하다.
- [0026] 명세서 전체에서, 어떤 부분이 다른 부분과 "연결"되어 있다고 할 때, 이는 직접적으로 연결되어 있는 경우뿐 아니라, 간접적으로 연결되어 있는 경우를 포함하고, 간접적인 연결은 무선 통신망을 통해 연결되는 것을 포함한다.
- [0027] 또한 어떤 부분이 어떤 구성요소를 "포함"한다고 할 때, 이는 특별히 반대되는 기재가 없는 한 다른 구성요소를 제외하는 것이 아니라 다른 구성요소를 더 포함할 수 있는 것을 의미한다.
- [0028] 명세서 전체에서, 어떤 부재가 다른 부재 "상에" 위치하고 있다고 할 때, 이는 어떤 부재가 다른 부재에 접해 있는 경우뿐 아니라 두 부재 사이에 또 다른 부재가 존재하는 경우도 포함한다.
- [0029] 제 1, 제 2 등의 용어는 하나의 구성요소를 다른 구성요소로부터 구별하기 위해 사용되는 것으로, 구성요소가 전술된 용어들에 의해 제한되는 것은 아니다.
- [0030] 단수의 표현은 문맥상 명백하게 예외가 있지 않는 한, 복수의 표현을 포함한다.
- [0031] 각 단계들에 있어 식별부호는 설명의 편의를 위하여 사용되는 것으로 식별부호는 각 단계들의 순서를 설명하는 것이 아니며, 각 단계들은 문맥상 명백하게 특정 순서를 기재하지 않는 이상 명기된 순서와 다르게 실시될 수 있다.
- [0032] 이하 첨부된 도면들을 참고하여 본 개시의 작용 원리 및 실시예들에 대해 설명한다.
- [0033] 본 명세서에서 '본 개시에 따른 장치'는 연산처리를 수행하여 사용자에게 결과를 제공할 수 있는 다양한 장치들이 모두 포함된다. 예를 들어, 본 개시에 따른 장치는, 컴퓨터, 서버 장치 및 휴대용 단말기를 모두 포함하거나, 또는 어느 하나의 형태가 될 수 있다.
- [0034] 여기에서, 상기 컴퓨터는 예를 들어, 웹 브라우저(WEB Browser)가 탑재된 노트북, 데스크톱(desktop), 랩톱(laptop), 태블릿 PC, 슬레이트 PC 등을 포함할 수 있다.
- [0035] 상기 서버 장치는 외부 장치와 통신을 수행하여 정보를 처리하는 서버로써, 애플리케이션 서버, 컴퓨팅 서버, 데이터베이스 서버, 파일 서버, 게임 서버, 메일 서버, 프록시 서버 및 웹 서버 등을 포함할 수 있다.
- [0036] 상기 휴대용 단말기는 예를 들어, 휴대성과 이동성이 보장되는 무선 통신 장치로서, PCS(Personal Communication System), GSM(Global System for Mobile communications), PDC(Personal Digital Cellular), PHS(Personal Handyphone System), PDA(Personal Digital Assistant), IMT(International Mobile Telecommunication)-2000, CDMA(Code Division Multiple Access)-2000, W-CDMA(W-Code Division Multiple Access), WiBro(Wireless Broadband Internet) 단말, 스마트 폰(Smart Phone) 등과 같은 모든 종류의 핸드헬드(Handheld) 기반의 무선 통신 장치와 시계, 반지, 팔찌, 발찌, 목걸이, 안경, 콘택트 렌즈, 또는 머리 착용형 장치(head-mounted-device(HMD)) 등과 같은 웨어러블 장치를 포함할 수 있다.
- [0037] 본 개시에 따른 인공지능과 관련된 기능은 프로세서와 메모리를 통해 동작된다. 프로세서는 하나 또는 복수의 프로세서로 구성될 수 있다. 이때, 하나 또는 복수의 프로세서는 CPU, AP, DSP(Digital Signal Processor) 등과 같은 범용 프로세서, GPU, VPU(Vision Processing Unit)와 같은 그래픽 전용 프로세서 또는 NPU와 같은 인공지능 전용 프로세서일 수 있다. 하나 또는 복수의 프로세서는, 메모리에 저장된 기 정의된 동작 규칙 또는 인

공지능 모델에 따라, 입력 데이터를 처리하도록 제어한다. 또는, 하나 또는 복수의 프로세서가 인공지능 전용 프로세서인 경우, 인공지능 전용 프로세서는, 특정 인공지능 모델의 처리에 특화된 하드웨어 구조로 설계될 수 있다.

[0038] 기 정의된 동작 규칙 또는 인공지능 모델은 학습을 통해 만들어진 것을 특징으로 한다. 여기서, 학습을 통해 만들어진다는 것은, 기본 인공지능 모델이 학습 알고리즘에 의하여 다수의 학습 데이터들을 이용하여 학습됨으로써, 원하는 특성(또는, 목적)을 수행하도록 설정된 기 정의된 동작 규칙 또는 인공지능 모델이 만들어짐을 의미한다. 이러한 학습은 본 개시에 따른 인공지능이 수행되는 기기 자체에서 이루어질 수도 있고, 별도의 서버 및/또는 시스템을 통해 이루어질 수도 있다. 학습 알고리즘의 예로는, 지도형 학습(supervised learning), 비지도형 학습(unsupervised learning), 준지도형 학습(semi-supervised learning) 또는 강화 학습(reinforcement learning)이 있으나, 전술한 예에 한정되지 않는다.

[0039] 인공지능 모델은, 복수의 신경망 레이어들로 구성될 수 있다. 복수의 신경망 레이어들 각각은 복수의 가중치들(weight values)을 갖고 있으며, 이전(previous) 레이어의 연산 결과와 복수의 가중치들 간의 연산을 통해 신경망 연산을 수행한다. 복수의 신경망 레이어들이 갖고 있는 복수의 가중치들은 인공지능 모델의 학습 결과에 의해 최적화될 수 있다. 예를 들어, 학습 과정 동안 인공지능 모델에서 획득한 로스(loss) 값 또는 코스트(cost) 값이 감소 또는 최소화되도록 복수의 가중치들이 갱신될 수 있다. 인공 신경망은 심층 신경망(DNN: Deep Neural Network)를 포함할 수 있으며, 예를 들어, CNN (Convolutional Neural Network), DNN (Deep Neural Network), RNN (Recurrent Neural Network), RBM (Restricted Boltzmann Machine), DBN (Deep Belief Network), BRDNN(Bidirectional Recurrent Deep Neural Network) 또는 심층 Q-네트워크 (Deep Q-Networks) 등이 있으나, 전술한 예에 한정되지 않는다.

[0040] 본 개시의 예시적인 실시예에 따르면, 프로세서는 인공지능을 구현할 수 있다. 인공지능이란 사람의 신경세포(biological neuron)를 모사하여 기계가 학습하도록 하는 인공신경망(Artificial Neural Network) 기반의 기계 학습법을 의미한다. 인공지능의 방법론에는 학습 방식에 따라 훈련데이터로서 입력데이터와 출력데이터가 같이 제공됨으로써 문제(입력데이터)의 해답(출력데이터)이 정해져 있는 지도학습(supervised learning), 및 출력데이터 없이 입력데이터만 제공되어 문제(입력데이터)의 해답(출력데이터)이 정해지지 않는 비지도학습(unsupervised learning), 및 현재의 상태(State)에서 어떤 행동(Action)을 취할 때마다 외부 환경에서 보상(Reward)이 주어지는데, 이러한 보상을 최대화하는 방향으로 학습을 진행하는 강화학습(reinforcement learning)으로 구분될 수 있다. 또한, 인공지능의 방법론은 학습 모델의 구조인 아키텍처에 따라 구분될 수도 있는데, 널리 이용되는 딥러닝 기술의 아키텍처는, 합성곱신경망(CNN; Convolutional Neural Network), 순환신경망(RNN; Recurrent Neural Network), 트랜스포머(Transformer), 생성적 대립 신경망(GAN; generative adversarial networks) 등으로 구분될 수 있다.

[0041] 이하, 첨부된 도면을 참조하여 본 개시의 실시예를 상세하게 설명한다.

[0042] 도 1은 본 개시의 생성 모델 평가 장치(1)의 구성을 나타내는 블록도이고, 도 2는 본 개시의 생성 모델 평가 장치(1)의 동작을 나타내는 순서도이다.

[0043] 도 1 및 2를 참조하면, 본 개시의 생성 모델 평가 장치(1)는 입력 데이터를 수치화된 특징 벡터로 변환하는 특징 임베딩부(10), 상기 특징 벡터에 기초하여 데이터 분포를 추정하는 확률 분포 추정부(20), 컨피던스 밴드를 추정하는 컨피던스 밴드 추정부(30), 및 TopP 및 TopR에 기초하여 생성 모델을 평가하는 평가부(40)를 포함할 수 있다.

[0044] 본 개시의 생성 모델 평가 장치(1)는 토폴로지컬 데이터 분석(TDA(Topological Data Analysis)의 지속적 호몰로지(persistent homology)를 기반으로 데이터의 실제 신호(real signal)만을 이용하여 데이터 분포를 추정할 수 있다.

[0045] 또한, 생성 모델 평가 장치(1)는 여러 가지 노이즈(예. outlier, IID & Non-IID perturbation)가 포함되어 있는 이미지 데이터셋의 분포를 근사할 때, 새롭게 정의한 신뢰구간을 바탕으로 노이즈 시그널(noisy signal)에 대해 강건한 데이터 분포를 추정할 수 있다.

[0046] 생성 모델 평가 장치(1)는 추정된 데이터 분포를 바탕으로 이미지의 명료성과 다양성을 정확하게 평가할 수 있으며, 여러 가지 임베딩 공간(embedding space)에서 일관적인 평가를 제시할 수 있는 평가 매트릭스를 제공할 수 있다.

[0047] 또한, 생성 모델 평가 장치(1)는 IS 혹은 FID와 같이 단일 평가점수를 통해 생성 모델의 성능에 따라서 모델의

순위를 평가할 수 있는 방법을 제공할 수 있다.

- [0048] 구체적으로, 도 2에서 보듯이, 생성 모델 평가 장치(1)는 입력 데이터를 수치화된 특징 벡터로 변환(동작 210)하고, 특징 벡터에 기초하여 데이터 분포를 추정(동작 220)하며, 컨피던스 밴드를 추정(동작 230)하고, TopP 및 TopR에 기초하여 생성 모델을 평가(동작 240)할 수 있다.
- [0049] 일 예에 따르면, 동작 210에서, 생성 모델 평가 장치(1)는 입력 데이터를 수치화된 특징 벡터로 변환할 수 있다. 예를 들어, 특징 임베딩부(10)는 입력 데이터(예. 이미지, 텍스트)를 수치화된 특징 벡터로 변환할 수 있다.
- [0050] 특징 임베딩부(10)는 입력 데이터를 특징 벡터로 변환하고, 특징 벡터를 확률 분포 추정부(20)로 전송함으로써, 확률 분포 추정부(20)가 입력 데이터의 복잡한 패턴을 이해하고, 이를 기반으로 새로운 샘플을 생성할 수 있도록 도울 수 있다. 특징 임베딩부(10)는 입력 데이터의 핵심적인 특징을 추출하여, 이후 평가부(40)가 TopP 및 TopR에 기초하여 생성 모델을 평가하도록 도울 수 있다.
- [0051] 일 예에 따르면, 동작 220에서, 생성 모델 평가 장치(1)는 특징 벡터에 기초하여 데이터 분포를 추정할 수 있다. 예를 들어, 확률 분포 추정부(20)는 생성된 샘플이 어떤 데이터 분포를 가지고 있는지를 근사할 수 있다.
- [0052] 예를 들어, 확률 분포 추정부(20)는 생성된 데이터가 취할 수 있는 값들의 집합, 즉, 가능한 데이터 범위를 추정할 수 있다. 확률 분포 추정부(20)는 생성 모델이 얼마나 넓은 범위의 데이터를 생성할 수 있는지를 추정할 수 있다. 확률 분포 추정부(20)는 생성된 데이터가 실제 데이터 분포를 얼마나 잘 반영하는지를 추정할 수 있다.
- [0053] 일 예에 따르면, 동작 230에서, 생성 모델 평가 장치(1)는 컨피던스 밴드를 추정할 수 있다. 예를 들어, 컨피던스 밴드 추정부(30)는 생성된 샘플들 사이의 통계적 다양성을 추정 및 평가할 수 있다.
- [0054] 예를 들어, 컨피던스 밴드 추정부(30)는 생성 모델이 다양한 유형의 샘플을 생성할 수 있는지 여부를 추정 및 분석할 수 있다. 구체적으로, 컨피던스 밴드 추정부(30)는 통계적 접근을 사용하여 데이터에서 위상적으로 중요한 특징을 식별하고, 이를 노이즈 데이터로부터 구할 수 있다.
- [0055] 컨피던스 밴드는 데이터의 특정 통계적 범위를 나타낼 수 있다. 니다. 컨피던스 밴드는 데이터 포인트들이 어떤 중요한 특성(예: 평균, 중앙값)을 갖을 확률적 범위를 나타내며, 특정 신뢰수준(significance level) 하에서 정의될 수 있다.
- [0056] 신뢰수준은 통계적 가설 검정에서 사용되는 개념으로, 잘못된 결론을 도출할 확률의 상한을 의미할 수 있다. 일반적으로 0.05(5%) 또는 0.01(1%) 등의 값이 사용될 수 있다. 예를 들어, 신뢰수준이 낮을수록 결론의 신뢰도는 높아질 수 있다.
- [0057] 부스트 트랩(Bootstrap) 방법은 통계적 추정치의 분포를 평가하기 위해 사용되는 방법일 수 있다. 부스트 트랩 방법은 원본 데이터셋에서 반복적으로 샘플을 추출하여 여러 데이터셋을 생성하고, 이를 통해 통계적 추정치의 분포를 얻을 수 있다. 예를 들어, 제1 알고리즘(Algorithm 1)은 이러한 부스트 트랩 방법을 구현하는 특정 알고리즘을 의미하며, 여기서는 부스트 트랩을 통해 얻은 대역폭(bandwidth)에 대한 컨피던스 밴드를 정의하는 데 사용될 수 있다.
- [0058] 컨피던스 밴드 추정부(30)는 데이터 내의 위상적으로 중요한 특징(예: 데이터 구조의 중요한 패턴이나 클러스터)을 식별할 수 있다. 예를 들어, 컨피던스 밴드 추정부(30)는 실제 데이터셋과 생성된 데이터셋 모두에서 적용하며, 정의된 컨피던스 밴드 내에서 중요한 특징들을 식별함으로써 노이즈 데이터와 구별할 수 있다.
- [0059] 컨피던스 밴드 추정부(30)는 복잡한 데이터셋에서 유의미한 통계적 특징을 추출하고, 이를 기반으로 데이터의 품질을 평가하거나, 머신 러닝 모델의 성능을 개선하는 데 중요한 역할을 할 수 있다. 컨피던스 밴드 추정부(30)는 입력 데이터의 본질적인 특성을 더 깊이 이해하고, 더 정확한 분석 및 예측 모델을 구축하는 데 도움을 줄 수 있다.
- [0060] 일 예에 따르면, 동작 240에서, 생성 모델 평가 장치(1)는 TopP 및 TopR에 기초하여 생성 모델을 평가할 수 있다. 예를 들어, 평가부(40)는 TopP(Top Precision) 평가 및 TopR(Top Recall) 평가를 기반으로 하여 생성 모델의 성능을 정교하게 측정할 수 있다. TopP 평가 및 TopR 평가는 생성 모델이 생성한 데이터의 품질과 다양성을 평가하는 데 중요한 역할을 할 수 있다.
- [0061] 예를 들어, 평가부(40)는 TopP 평가를 통해 생성된 데이터 샘플들 중 실제 데이터 분포와 가장 가까운 상위 퍼

센트의 데이터가 얼마나 정확한지를 평가할 수 있다. TopP 평가는 생성 모델이 실제 데이터와 얼마나 유사한 고품질의 결과물을 만들어내는지를 측정하는 지표로 사용될 수 있다.

[0062] 예를 들어, 평가부(40)는 TopR 평가를 통해 실제 데이터 분포를 생성 모델이 얼마나 잘 커버하는지를 평가할 수 있다. TopR은 생성 모델이 실제 데이터의 전체 범위를 얼마나 잘 반영하는지를 나타낼 수 있다. 즉, TopR은 생성된 데이터의 다양성을 측정하는 데 중요한 지표로 사용될 수 있다.

[0063] 생성 모델의 성능은 두 가지 주요 요소인 '정확성(충실도)'과 '다양성'의 측면에서 종합적으로 평가될 수 있다. 예를 들어, TopP는 모델이 얼마나 정확하게 데이터를 생성하는지, TopR은 모델이 데이터의 다양성을 얼마나 잘 포착하는지를 각각 나타낼 수 있다. 평가부(40)는 상기 TopP 및 상기 TopR 두 지표를 통해 생성 모델의 전반적인 품질과 효과를 정량적으로 파악할 수 있다.

[0064] 이와 같이, 생성 모델 평가 장치(1)는 토폴로지컬 데이터 분석(Topological Data Analysis, TDA) 방법을 활용하여 노이즈(noisy)한 정보에 의한 영향을 받지 않는 강건한 추정 기법을 활용할 수 있다. 생성 모델 평가 장치(1)가 사용하는 토폴로지컬 데이터 분석(TDA)의 지속적 호몰로지(persistent homology)는 데이터 분포가 가지고 있는 위상적 특성을 확인할 수 있는 방법 중 하나일 수 있다. 생성 모델 평가 장치(1)는 지속적 호몰로지를 기반으로 데이터의 실제 신호(real signal)만을 이용하여 데이터 분포를 근사하는 접근 방식을 취할 수 있다.

[0065] 한편, 본 개시의 생성 모델 평가 장치(1)는 인공지능 모델을 포함할 수 있다. 인공지능 모델은 하나의 인공지능 모델일 수 있고, 복수의 인공지능 모델로 구현될 수도 있다. 인공지능 모델은 뉴럴 네트워크(또는 인공 신경망)로 구성될 수 있으며, 기계학습과 인지과학에서 생물학의 신경을 모방한 통계학적 학습 알고리즘을 포함할 수 있다. 뉴럴 네트워크는 시냅스의 결합으로 네트워크를 형성한 인공 뉴런(노드)이 학습을 통해 시냅스의 결합 세기를 변화시켜, 문제 해결 능력을 가지는 모델 전반을 의미할 수 있다. 뉴럴 네트워크의 뉴런은 가중치 또는 바이어스의 조합을 포함할 수 있다. 뉴럴 네트워크는 하나 이상의 뉴런 또는 노드로 구성된 하나 이상의 레이어(layer)를 포함할 수 있다. 예시적으로, 장치는 input layer, hidden layer, output layer를 포함할 수 있다. 장치를 구성하는 뉴럴 네트워크는 뉴런의 가중치를 학습을 통해 변화시킴으로써 임의의 입력(input)으로부터 예측하고자 하는 결과(output)를 추론할 수 있다.

[0066] 생성 모델 평가 장치(1)에 포함된 적어도 하나의 프로세서는 뉴럴 네트워크를 생성하거나, 뉴럴 네트워크를 훈련(train, 또는 학습(learn)하거나, 수신되는 입력 데이터를 기초로 연산을 수행하고, 수행 결과를 기초로 정보 신호(information signal)를 생성하거나, 뉴럴 네트워크를 재훈련(retrain)할 수 있다. 뉴럴 네트워크의 모델들은 GoogleNet, AlexNet, VGG Network 등과 같은 CNN(Convolution Neural Network), R-CNN(Region with Convolution Neural Network), RPN(Region Proposal Network), RNN(RecurEnt Neural Network), S-DNN(Stacking-based deep Neural Network), S-SDNN(State-Space Dynamic Neural Network), Deconvolution Network, DBN(Deep Belief Network), RBM(Restrcted Boltzman Machine), Fully Convolutional Network, LSTM(Long Short-Term Memory) Network, Classification Network 등 다양한 종류의 모델들을 포함할 수 있으나 이에 제한되지는 않는다. 프로세서는 뉴럴 네트워크의 모델들에 따른 연산을 수행하기 위한 하나 이상의 프로세서서를 포함할 수 있다. 예를 들어 뉴럴 네트워크는 심층 뉴럴 네트워크 (Deep Neural Network)를 포함할 수 있다.

[0067] 뉴럴 네트워크는 CNN(Convolutional Neural Network), RNN(RecurEnt Neural Network), 퍼셉트론(perceptron), 다층 퍼셉트론(multilayer perceptron), FF(Feed Forward), RBF(Radial Basis Network), DFF(Deep Feed Forward), LSTM(Long Short Term Memory), GRU(Gated RecurEnt Unit), AE(Auto Encoder), VAE(Variational Auto Encoder), DAE(Denoising Auto Encoder), SAE(Sparse Auto Encoder), MC(Markov Chain), HN(Hopfield Network), BM(Boltzmann Machine), RBM(Restricted Boltzmann Machine), DBN(Depp Belief Network), DCN(Deep Convolutional Network), DN(Deconvolutional Network), DCIGN(Deep Convolutional Inverse Graphics Network), GAN(Generative Adversarial Network), LSM(Liquid State Machine), ELM(Extreme Learning Machine), ESN(Echo State Network), DRN(Deep Residual Network), DNC(Differentiable Neural Computer), NTM(Neural Turning Machine), CN(Capsule Network), KN(Kohonen Network) 및 AN(Attention Network)를 포함할 수 있으나 이에 한정되는 것이 아닌 임의의 뉴럴 네트워크를 포함할 수 있음은 통상의 기술자가 이해할 것이다.

[0068] 본 개시의 예시적인 실시예에 따르면, 생성 모델 평가 장치(1)에 포함된 적어도 하나의 프로세서는 GoogleNet, AlexNet, VGG Network 등과 같은 CNN(Convolution Neural Network), R-CNN(Region with Convolution Neural Network), RPN(Region Proposal Network), RNN(RecurEnt Neural Network), S-DNN(Stacking-based deep Neural

Network), S-SDNN(State-Space Dynamic Neural Network), Deconvolution Network, DBN(Deep Belief Network), RBM(Restrcted Boltzman Machine), Fully Convolutional Network, LSTM(Long Short-Term Memory) Network, Classification Network, Generative Modeling, eXplainable AI, Continual AI, Representation Learning, AI for Material Design, 자연어 처리를 위한 BERT, SP-BERT, MRC/QA, Text Analysis, Dialog System, GPT-3, GPT-4, 비전 처리를 위한 Visual Analytics, Visual Understanding, Video Synthesis, ResNet 데이터 지능을 위한 Anomaly Detection, Prediction, Time-Series Forecasting, Optimization, Recommendation, Data Creation 등 다양한 인공지능 구조 및 알고리즘을 이용할 수 있으며, 이에 제한되지 않는다.

[0069] 도 3은 본 개시의 생성 모델 평가 장치(1)의 컨피던스 밴드의 부스트 스트랩핑을 통한 근사를 나타내는 도면이고, 도 4는 본 개시의 생성 모델 평가 장치(1)의 강건한 데이터 분포에 대한 근사를 나타내는 도면이며, 도 5는 본 개시의 생성 모델 평가 장치(1)의 단계, TopP&R을 통한 평가 점수 계산을 나타내는 도면이이고, 도 6은 본 개시의 생성 모델 평가 장치(1)의 컨피던스 밴드 추정부(30)가 이용하는 제1 알고리즘을 나타내는 도면이다.

[0070] 도 3 내지 6을 참조하면, 생성 모델 평가 장치(1)는 통계적으로 보수적인 관점에서 생성 모델의 성능을 평가할 수 있다. 생성 모델 평가 장치(1)는 위상적으로 중요한 구조를 가지고 있는 데이터 혹은 통계적으로 신뢰할 수 있는 데이터들을 이용하는 매트릭(metric)에 기초하여 생성 모델의 성능을 평가할 수 있다.

[0071] 생성 모델 평가 장치(1)는 지속적 호몰로지(persistent homology)를 활용한 토폴로지컬 데이터 분석(TDA)을 통해, 입력 데이터를 다양한 레솔루션(resolution)에서 관찰할 수 있다. 생성 모델 평가 장치(1)는 입력 데이터를 다양한 레솔루션에서 관찰하는 과정을 통해 입력 데이터의 위상적으로 중요한 특징을 정량화하며 추출할 수 있다.

[0072] 필터레이션(filtration)은 데이터 포인트를 다양한 레솔루션에서 근사하는 부분 공간들의 집합이며, 일반적으로 $F = \{F_\delta \subset \mathbb{R}^d\}_{\delta \in \mathbb{R}}$ 라고 표기하며 $\delta_1 \leq \delta_2$ 일 때 $F_{\delta_1} \subset F_{\delta_2}$ 와 같은 관계를 만족한다.

[0073] 생성 모델 평가 장치(1)에 포함된 확률 분포 추정부(20)는 데이터 분포를 근사하는 함수 $f: \mathbb{R}^d \rightarrow \mathbb{R}$ 를 이용하여 필터레이션을 정의할 수 있다. 함수 $f: \mathbb{R}^d \rightarrow \mathbb{R}$ 는 분포를 직접 근사하기 위해 컴팩트(compact)한 코사인 커널(cosine kernel)을 기반으로 하는 KDE를 사용하며, 필터레이션을 $\{f^{-1}(-\infty, \delta]\}_{\delta \in \mathbb{R}}$ 로 정의할 수 있다. 여기서 파라미터 δ 는 노이즈 데이터 포인트를 제외해주는 쓰레스홀드(threshold)로 사용된다.

[0074] 도 3에서 보듯이, 확률 분포 추정부(20)는 KDE를 필터레이션(filtration)에 관계된 함수 f 로 활용하여 데이터의 분포 $\{f^{-1}[\delta, \infty)\}_{\delta \in \mathbb{R}}$ 를 근사할 수 있다. 데이터의 분포를 구성하는 데이터는 중요한 위상적 구조의 생존 기간으로 결정되기 때문에, 생성 모델 평가 장치(1)는 중요한 위상적 특징을 잘 유지할 수 있게 해주는 데이터를 걸러주는 쓰레스홀드(threshold) c_α 를 계산할 수 있다.

[0075] 지속적 호몰로지는 위상적인 특징(homology)을 표현하는 방법으로 2차원의 지속적 다이어그램(persistent diagram)에서 시각화가 가능하다. 필터레이션 F 를 이용하여 k차원에 위에 있는 위상적인 특징(예. 0-dimension: connected component, 1-dimension: loop, 2-dimension: cavity, ...)이 태어나고(birth) 없어지는(death) 과정을 기록할 수 있다. 필터레이션 $\{F_\delta\}$ 에서 δ 의 증가 혹은 감소에 따라서 호몰로지가 F_δ 에서 생겨나고 F_δ 에서 없어진다. 필터레이션을 통해서 얻은 좌표(coordinate) $\{(b, d)\}$ 는 공간 $(\mathbb{R} \cup \{\pm \infty\})^2$ 위의 점으로 나타내며, 이것을 지속적 다이어그램(persistent diagram)이라고 한다. 여기서, $d-b$ 를 통해 호몰로지의 생존기간을 계산할 수 있고, 오래 살아있는 호몰로지(homology)가 데이터 셋에서 위상적으로 중요한 특징을 지니고 생존기간이 짧을수록(예컨대, 대각선 $\{(\delta, \delta): \delta \in \mathbb{R}\}$ 와 가까울수록) 위상적으로 노이즈한 특징에 해당한다.

[0076] 생성 모델 평가 장치(1)에 포함된 컨피던스 밴드 추정부(30)는 통계적 지표인 유의 수준(significance level) α 를 기반으로 중요한 위상적 특징을 정의할 수 있는 쓰레스홀드(threshold) $c_\alpha = (d-b)$ 를 근사할 수 있다.

[0077] 도 4에서 보듯이, 컨피던스 밴드 추정부(30)는 확률 분포 추정부(20)에서 정의한 c_α 를 이용하여 위상적으로 중요한 구조를 가지며 노이즈 신호에 대해 강건한 데이터 분포 $f^{-1}[\delta, \infty)$ 를 추정(또는 근사)할 수 있다.

[0078] 구체적으로, 컨피던스 밴드 추정부(30)는 유의 수준(Significance level) α 가 주어졌을 때, c_α 는 제1 알고리즘

(예. 도 6의 제1 알고리즘)을 통해 구한 부스트트랩 대역폭(bootstrap bandwidth) $\|\hat{p}_h - p_h\|_\infty$ 에 대한 컨피던스 밴드라고 정의할 수 있다.

[0079] 앞서 정의한 c_α 는 $\liminf_{n \rightarrow \infty} P(\|\hat{p}_h - p_h\|_\infty < c_\alpha) \geq 1 - \alpha$ 를 만족할 수 있다. 이렇게 정의한 컨피던스 밴드는 위상적으로 중요한 특징을 보장하는 데이터를 노이즈한 데이터로부터 분류해주는 역할을 한다. 생성 모델 평가 장치(1)는 유의 수준 α 하에서 각 실제 데이터셋 X 와 생성 데이터셋 Y 에 대해 정의한 컨피던스 밴드를 c_x 와 c_y 라고 표기할 수 있다.

[0080] KDE의 커널 대역폭(kernel bandwidth) h 는 근사가 필요한 하이퍼 파라미터(hyper parameter)이다. 생성 모델 평가 장치(1)는 커널 대역폭에 대한 근사를 위해, h 변화에 따른 데이터의 위상적 특성의 변화를 지속적 다이어그램(persistent diagram)을 통해 관측할 수 있다. 생성 모델 평가 장치(1)는 지속적 다이어그램(Persistent diagram)에서 i 번째 호몰로지에 대한 위상적인 중요성을 나타내는 지표 (b_i, d_i) 를 이용하여 i 번째 호몰로지의 생존 기간 $l_i(h) = d_i - b_i$ 을 계산할 수 있다. 컨피던스 밴드 $c_\alpha(h)$ 가 주어졌을 때, 최적의 값을 가지는 h 는 아래 [수식1] 중 어느 하나를 최대화할 수 있다.

[0081] [수식1]

[0082]
$$N(h) = \{i : l_i(h) > c_\alpha(h)\}, S(h) = \sum_i [l_i(h) - c_\alpha(h)]_+$$

[0083] 생성 모델 평가 장치(1)는 TopP 및 TopR을 계산함으로써, 생성 모델이 생성한 이미지들의 명료성과 다양성을 정량적으로 평가하는 점수를 얻을 수 있다.

[0084] 예를 들어, 도 5에서 보듯이, 생성 모델 평가 장치(1)는 정밀도(precision)를 통해서 생성 모델의 품질(fidelity)을 측정할 때, 생성 데이터 분포가 얼마나 실제 데이터 분포와 가깝게 위치하는지 측정할 수 있다. 또한, 생성 모델 평가 장치(1)는 재현율(recall)을 통해 다양성(diversity)을 측정할 때, 생성 모델이 생성 데이터의 분포가 실제 데이터 분포가 가지는 다양성 혹은 분산과 유사한 분포를 가지는지 측정할 수 있다.

[0085] 생성 모델 평가 장치(1)는 실수 공간 R^d 위에 정의된 데이터 분포 P 가 가지는 분포(support)를 이용하여 정밀도 및 재현율을 재정의할 수 있다.

[0086] 생성 모델 평가 장치(1)는 모든 데이터 x 와 $r > 0$ 에 대해서 $B_d(x, r) = \{y : d(y, x) < r\}$ 는 중심 x 와 반지름 r 을 가지는 경계를 포함하지 않는 원이라고 정의할 수 있다. 실수 공간 R^d 위에 정의되는 데이터 분포 P 가 가지는 support를 수학적으로 정의하면, $supp(P) := \{x \in R^d : P(B(x, r)) > 0 \text{ for all } r > 0\}$ 와 같이 표기할 수 있다.

[0087] 데이터 $X = \{X_1, \dots, X_n\} \subset R^d$, 데이터에 대한 커널 함수 $K: R^d \rightarrow R$, 그리고 커널 대역폭 $h > 0$ 가 주어졌을 때, 분포를 근사해주는 커널 밀도 추정기(KDE)는 아래 수식 2와 같이 정의될 수 있다.

[0088] [수식 2]

[0089]
$$\hat{p}_h(x) := \frac{1}{nh^d} \sum_{i=1}^n K\left(\frac{x - X_i}{h}\right)$$

[0090] 여기서, KDE의 평균은 $p_h := E[\hat{p}_h]$ 를 만족할 수 있다. 생성 모델 평가 장치(1)는 노이즈 데이터를 포함할 수 있는 생성 데이터 $Y = \{Y_1, \dots, Y_m\} \subset R^d$ 가 가지는 확률 분포를 Q 라고 표기하며, 실제 데이터 $X = \{X_1, \dots, X_n\} \subset R^d$ 가 가지는 확률 분포는 P 라고 정의할 수 있다.

[0091] 생성 모델 평가 장치(1)에 포함된 평가부(40)는 정밀도(precision)와 재현율(recall)을 기존의 방식과 변형하여 적용할 수 있다. 정밀도는 $precision_P(Y) = Q(supp(P) \cap supp(Q)) / Q(supp(Q))$ 라고 정의할 수 있다. 여기서, 정밀도를 데이터 포인트들에 대해서 정의하면 아래 [수식 3]과 같다.

[0092] [수식 3]

$$precision_P(Y) := \frac{\sum_{j=1}^m 1(Y_j \in supp(P) \cap supp(Q))}{\sum_{j=1}^m 1(Y_j \in supp(Q))}$$

[0093]

[0094] 위에서 정밀도를 정의한 것과 유사하게 재현율은 아래 [수식 4]와 같이 정의할 수 있다.

[0095] [수식 4]

$$recall_Q(X) := \frac{\sum_{i=1}^n 1(X_i \in supp(P) \cap supp(Q))}{\sum_{i=1}^n 1(X_i \in supp(P))}$$

[0096]

[0097] 실제로 정밀도와 재현율을 정의할 때, $supp(P)$ 와 $supp(Q)$ 는 주어지지 않기 때문에 근사가 필요할 수 있다. 상기

분포는(support)는 앞서 정의한 KDE $\hat{p}_{h_n}(x) := \frac{1}{nh_n} \sum_{i=1}^n K(\frac{x-X_i}{h_n})$ 와 컨피던스 밴드 c_X 를 이용해서 계산될 수 있다.

[0098] 예를 들어, c_X 에서의 P 의 분포는 $\widehat{supp}(P) = \hat{p}_{h_n}^{-1}[c_X, \infty)$ 로 근사되며, 이 과정에서 KDE값이 낮은값을 가지기 때문에 에 노이즈로 추정되는 데이터들을 제외하게 된다. 이와 유사하게, Q 의 support를 $\widehat{supp}(Q) = \hat{q}_{h_m}^{-1}[c_Y, \infty)$ 로 정의할 수 있다. 최종적으로 이렇게 근사한 P 와 Q 의 분포를 이용하여 위의 정밀도 및 재현율을 정의하면 아래와 같이 아래 [수식 5] 및 [수식 6]과 같이 토폴로지컬 정밀도 및 토폴로지컬 재현율을 얻을 수 있다.

[0099] [수식 5]

$$TopP_X(Y) := \frac{\sum_{j=1}^m 1(Y_j \in \widehat{supp}(P) \cap \widehat{supp}(Q))}{\sum_{j=1}^m 1(Y_j \in \widehat{supp}(Q))} = \frac{\sum_{j=1}^m 1(\hat{p}_{h_n}(Y_j) > c_X, \hat{q}_{h_m}(Y_j) > c_Y)}{\sum_{j=1}^m 1(\hat{q}_{h_m}(Y_j) > c_Y)},$$

[0100]

[0101] [수식 6]

$$TopR_Y(X) := \frac{\sum_{i=1}^n 1(X_i \in \widehat{supp}(Q) \cap \widehat{supp}(P))}{\sum_{i=1}^n 1(X_i \in \widehat{supp}(P))} = \frac{\sum_{i=1}^n 1(\hat{q}_{h_m}(X_i) > c_Y, \hat{p}_{h_n}(X_i) > c_X)}{\sum_{i=1}^n 1(\hat{p}_{h_n}(X_i) > c_X)}$$

[0102]

[0103] 위의 [수식 5] 및 [수식 6]의 하이퍼 파라미터(hyper parameter)인 h_n 및 h_m 은 뽀론 추정기(balloon estimator)에 의해서 근사될 수 있다.

[0104] 평가부(40)에서 생성된 TopP 및 TopR은 상한과 하한이 분명한 점수를 가지는 장점이 있으며, 노이즈(noisy)한 데이터, 아웃라이어(outlier), 롱 테일 분포(long tailed distribution) 등의 조건하에서 일관적인 성능을 보이는 장점이 있다.

[0105] 이와 같이, 본 개시의 생성 모델 평가 장치(1)는 품질(Fidelity) 및 다양성(Diversity) 측면에서 위상적이면서도 통계적으로 생성 모델을 평가할 수 있으며, 종래의 매트릭들보다 더욱 강건하게 생성 모델을 평가함으로써, 생성 모델의 발전에 기여할 수 있다.

[0106] 도 7은 생성된 데이터 분포의 아웃라이어에 대한 평가 매트릭의 평가 경향을 나타내는 도면이다.

[0107] 도 7을 참조하면, synthetic dataset에서 제안한 복수의 매트릭이 아웃라이어(outlier)가 있는 데이터에서 강건하게 생성 모델을 평가할 수 있는지 여부에 대한 평가 매트릭의 평가 경향이 도시된다. 도 7의 x축은 생성 분포의 평균 μ 값을 나타낸다. 예를 들어, 도 7의 테스트에서는 10,000개의 생성 샘플을 생성 분포 $Y \sim \mathcal{N}(\mu 1, \sigma^2)$ 에서 무작위 추출하여 사용할 수 있다.

- [0108] 도 7에서 보듯이, μ 는 생성 분포의 위치에 따라서 $[-1, 1]$ 사이의 값으로 변동할 수 있다. 아웃라이어는 실제 분포와 생성 분포 모두 $3 \in \mathcal{R}^{d_z}$ 위치에 한 개의 샘플을 고려하였다. 테스트 결과를 통해서 기존의 P&R과 D&C, GCA 매트릭은 아웃라이어가 있을 때 정상적인 평가를 제공하지 못하는 것을 확인할 수 있다. 반면, 본 개시의 생성 모델 평가 장치(1)는 아웃라이어가 있을 때에도 정상적인 평가를 제공할 수 있다.
- [0109] 도 8은 순차적 모드 드롭 및 동시적 모드 드롭이 발생하는 경우 평가 매트릭의 평가 경향을 나타내는 도면이다.
- [0110] 도 8의 x축은 0을 중심으로 하는 분포(mode)의 샘플 집적도를 나타낸다.
- [0111] 도 8은 순차적 모드 드롭 및 동시적 모드 드롭을 시뮬레이션하여 본 개시의 생성 모델 평가 장치(1)에서 제안하는 매트릭이 기존의 매트릭에 비해서 민감하고 정확한 정량적 평가를 제공할 수 있는지에 대한 여부를 나타낸다.
- [0112] 생성 모델은 여러 가지 모드를 가지는 실제 이미지 분포를 모방하여 이미지의 여러 클래스에 해당하는 다양한 이미지를 생성하도록 학습될 수 있다. 제대로 학습이 되지 않은 생성 모델의 경우 특정 class의 이미지를 잘 생성하지 못하는 특징(mode dropping)을 가질 수 있고, 평가 매트릭은 이러한 경향을 가지는 생성 모델에 대해서 올바른 평가 점수를 주어야 한다.
- [0113] 도 8에서 보듯이, 생성 분포의 특정 모드의 샘플 개수를 줄일 때 중심이 0인 모드에 동일한 개수의 샘플을 보충하여 품질(fidelity)이 항상 1로 고정되게끔 설정할 수 있다. 특히, 매트릭들의 다양성에 대한 평가 경향을 보면, 본 개시의 생성 모델 평가 장치(1)의 TopR이 가장 민감하고 정확하게 실제 평가값이 가져야하는 경향을 따르고 있다는 것을 알 수 있다. 반면, 일부 다른 매트릭들은 동시적 모드 드롭 시뮬레이션에서 정상적으로 평가값을 반환하지 못하는 것을 확인할 수 있다.
- [0114] 도 9는 생성 모델의 순위를 비교하는 도표이다.
- [0115] 구체적으로 도 9는 FID를 통한 생성 모델의 순위와 TopP&R, D&C, P&R의 F1 score와 FID, KID, MTD를 통해 계산한 생성 모델의 순위에 대한 비교를 도시한다. 임베딩 네트워크(Embedding network)로는 InceptionV3, VGG16, 및 SwAV이 사용될 수 있다. 도표의 괄호안의 숫자는 각 매트릭이 평가한 생성 모델의 순위를 의미할 수 있다.
- [0116] 도 9에서 보듯이, 품질(Fidelity) 및 다양성(Diversity)을 각각 평가하는 기존의 D&C와 P&R과 같은 매트릭들은 정확한 데이터 분포를 안정적으로 근사하지 못하는 점과 D&C의 상한이 없는 평가값이라는 특징 때문에 다양한 생성 모델의 순위를 매기기 어렵다. 반면, 본 개시의 생성 모델 평가 장치(1)의 매트릭은 여러 가지 변화(perturbation)에 대해서 강건하고 데이터 분포를 정확하게 근사해주는 특징으로 인해, 여러 가지 임베딩 네트워크 세팅에서 생성 모델에 대해 FID와 일관적인 순위를 준다는 것을 확인할 수 있다.
- [0117] 각 매트릭으로 정의한 F1 score가 여러 임베딩 네트워크에 따라서 매긴 생성 모델의 순위가 일관적인지에 대해 알아보기 위해, 해밍 거리(Hamming Distance, HD)가 계산될 수 있다. 예를 들어, 도 9에서 보듯이, TopP&R, P&R, D&C, MTD의 HD 결과 값은 순서대로 1.33, 2.66, 3.0, 3.33으로 계산된다. 즉, 본 개시의 생성 모델 평가 장치(1)에 따른 TopP&R이 여러 가지 임베딩 네트워크 세팅에서 가장 일관적인 순위를 준다는 것을 확인할 수 있다.
- [0118] 이와 같이, 본 개시의 생성 모델 평가 장치(1)는 품질(Fidelity) 및 다양성(Diversity) 측면에서 위상적이면서도 통계적으로 생성 모델을 평가할 수 있으며, 종래의 매트릭들보다 더욱 강건하게 생성 모델을 평가함으로써, 생성 모델의 발전에 기여할 수 있다.
- [0119] 다만, 이에 대해서는 상술한 바 있으므로, 그에 대한 중복되는 설명은 생략하기로 한다.
- [0120] 이상에서 설명된 장치는 하드웨어 구성요소, 소프트웨어 구성요소, 및/또는 하드웨어 구성요소 및 소프트웨어 구성요소의 조합으로 구현될 수 있다. 예를 들어, 실시예들에서 설명된 장치 및 구성요소는, 예를 들어, 프로세서, 콘트롤러, ALU(arithmetic logic unit), 디지털 신호 프로세서(digital signal processor), 마이크로컴퓨터, FPA(field programmable array), PLU(programmable logic unit), 마이크로프로세서, 또는 명령(instruction)을 실행하고 응답할 수 있는 다른 어떠한 장치와 같이, 하나 이상의 범용 컴퓨터 또는 특수 목적 컴퓨터를 이용하여 구현될 수 있다. 처리 장치는 운영 체제(OS) 및 상기 운영 체제 상에서 수행되는 하나 이상의 소프트웨어 애플리케이션을 수행할 수 있다. 또한, 처리 장치는 소프트웨어의 실행에 응답하여, 데이터를 접근, 저장, 조작, 처리 및 생성할 수도 있다. 이해의 편의를 위하여, 처리 장치는 하나가 사용되는 것으로 설명된 경우도 있지만, 해당 기술분야에서 통상의 지식을 가진 자는, 처리 장치가 복수 개의 처리 요소(processing

element) 및/또는 복수 유형의 처리 요소를 포함할 수 있음을 알 수 있다. 예를 들어, 처리 장치는 복수 개의 프로세서 또는 하나의 프로세서 및 하나의 컨트롤러를 포함할 수 있다. 또한, 병렬 프로세서(parallel processor)와 같은, 다른 처리 구성(processing configuration)도 가능하다.

[0121] 실시예에 따른 방법은 다양한 컴퓨터 수단을 통하여 수행될 수 있는 프로그램 명령 형태로 구현되어 컴퓨터 판독 가능 매체에 기록될 수 있다. 상기 컴퓨터 판독 가능 매체는 프로그램 명령, 데이터 파일, 데이터 구조 등을 단독으로 또는 조합하여 포함할 수 있다. 상기 매체에 기록되는 프로그램 명령은 실시예를 위하여 특별히 설계되고 구성된 것들이거나 컴퓨터 소프트웨어 당업자에게 공지되어 사용 가능한 것일 수도 있다. 컴퓨터 판독 가능 기록 매체의 예에는 하드 디스크, 플로피 디스크 및 자기 테이프와 같은 자기 매체(magnetic media), CD-ROM, DVD와 같은 광기록 매체(optical media), 플롭티컬 디스크(floptical disk)와 같은 자기-광 매체(magneto-optical media), 및 롬(ROM), 램(RAM), 플래시 메모리 등과 같은 프로그램 명령을 저장하고 수행하도록 특별히 구성된 하드웨어 장치가 포함된다. 프로그램 명령의 예에는 컴파일러에 의해 만들어지는 것과 같은 기계어 코드뿐만 아니라 인터프리터 등을 사용해서 컴퓨터에 의해서 실행될 수 있는 고급 언어 코드를 포함한다. 상기된 하드웨어 장치는 실시예의 동작을 수행하기 위해 하나 이상의 소프트웨어 모듈로서 작동하도록 구성될 수 있으며, 그 역도 마찬가지이다.


[0122] 이상과 같이 실시예들이 비록 한정된 도면에 의해 설명되었으나, 해당 기술분야에서 통상의 지식을 가진 자라면 상기의 기재로부터 다양한 수정 및 변형이 가능하다. 예를 들어, 설명된 기술들이 설명된 방법과 다른 순서로 수행되거나, 및/또는 설명된 시스템, 구조, 장치, 회로 등의 구성요소들이 설명된 방법과 다른 형태로 결합 또는 조합되거나, 다른 구성요소 또는 균등물에 의하여 대치되거나 치환되더라도 적절한 결과가 달성될 수 있다. 그러므로, 다른 구현들, 다른 실시예들 및 특허청구범위와 균등한 것들도 후술하는 특허청구범위의 범위에 속한다.

부호의 설명


[0123] 1: 생성 모델 평가 장치
10: 특징 임베딩부
20: 확률 분포 추정부
30: 컨피던스 밴드 추정부
40: 평가부

도면


도면1



도면2




도면3




도면4

(b) Given confidence level $1 - \alpha$, bootstrap confidence band c_α computed from $\theta_1, \dots, \theta_k$ satisfies $\liminf_{n \rightarrow \infty} \mathbb{P}(\|\hat{p}_h - p_h\|_{\infty} < c_\alpha) \geq 1 - \alpha$



도면5

(c) Given $\widehat{\text{supp}}(P)$ for real features $\mathcal{X}$ and $\widehat{\text{supp}}(Q)$ for generated features $\mathcal{Y}$,



$$\text{Top}P_{\mathcal{X}}(\mathcal{Y}) := \frac{\sum_{j=1}^m 1(Y_j \in \widehat{\text{supp}}(P) \cap \widehat{\text{supp}}(Q))}{\sum_{j=1}^m 1(Y_j \in \widehat{\text{supp}}(Q))}$$

$$\text{Top}R_{\mathcal{Y}}(\mathcal{X}) := \frac{\sum_{i=1}^n 1(X_i \in \widehat{\text{supp}}(Q) \cap \widehat{\text{supp}}(P))}{\sum_{i=1}^n 1(X_i \in \widehat{\text{supp}}(P))}$$

도면6

Algorithm 1 Confidence Band Estimator

```


# KDE: kernel density estimator
# h: kernel bandwidth parameter
# k: number of repeats
#  $\hat{\theta}$ : set of difference

Given  $\mathcal{X} = \{X_1, X_2, \dots, X_n\}$ 
 $\hat{p}_h = \text{KDE}(\mathcal{X})$ 
for iteration = 1, 2, ..., k do
    # Define  $\mathcal{X}^*$  with bootstrap sampling
     $\mathcal{X}^*$  = random sample  $n$  times with repeat from  $\mathcal{X}$ 
    #  $\hat{p}_h^*$  replaces population density
     $\hat{p}_h^* = \text{KDE}(\mathcal{X}^*)$ 
    # compute  $\hat{\theta}$  with bootstrap samples
    Append  $\hat{\theta}$  with  $\sqrt{n} \|\hat{p}_h - \hat{p}_h^*\|_{\infty}$ 
end for


# grid search for the confidence band
for  $q \in [\min(\hat{\theta}), \max(\hat{\theta})]$  do
    count = 0
    for element  $\in \hat{\theta}$  do
        if element > q then
            count = count + 1
        end if
    end for
    # define the band threshold
    if count/k  $\approx \alpha$  then
         $q_{\alpha} = q$ 
    end if
end for
# define estimated confidence band
 $c_{\alpha} = q_{\alpha} / \sqrt{n}$ 

```

도면7



도면8



도면9

	Model	StyleGAN2	ReACGAN	BigGAN	PDGAN	ACGAN	WGAN-GP
InceptionV3	FID (↓)	3.78 (1)	3.87 (2)	4.16 (3)	31.54 (4)	33.39 (5)	107.68 (6)
	KID (↓)	0.002 (1)	0.012 (3)	0.011 (2)	0.025 (4)	0.029 (5)	0.137 (6)
	TopP&R (↑)	0.9769 (1)	0.8457 (2)	0.7751 (3)	0.7339 (4)	0.6951 (5)	0.0163 (6)
	D&C (↑)	0.9626 (2)	0.9409 (3)	1.1562 (1)	0.4383 (4)	0.3883 (5)	0.1913 (6)
	P&R (↑)	0.6232 (1)	0.3320 (2)	0.3278 (3)	0.1801 (4)	0.0986 (5)	0.0604 (6)
	MTD (↓)	2.3380 (3)	2.2687 (2)	1.4473 (1)	7.0188 (4)	8.0728 (5)	11.498 (6)
VGG16	TopP&R (↑)	0.9754 (1)	0.5727 (3)	0.7556 (2)	0.4021 (4)	0.3463 (5)	0.0011 (6)
	D&C (↑)	0.9831 (3)	1.0484 (1)	0.9701 (4)	0.9872 (2)	0.8971 (5)	0.6372 (6)
	P&R (↑)	0.6861 (1)	0.1915 (3)	0.3526 (2)	0.0379 (4)	0.0195 (5)	0.0001 (6)
	MTD (↓)	25.757 (4)	25.826 (3)	34.755 (5)	24.586 (2)	23.318 (1)	41.346 (6)
SwAV	TopP&R (↑)	0.9093 (1)	0.3568 (3)	0.5578 (2)	0.1592 (4)	0.1065 (5)	0.0003 (6)
	D&C (↑)	1.0732 (1)	0.9492 (3)	1.0419 (2)	0.6328 (4)	0.4565 (5)	0.0721 (6)
	P&R (↑)	0.5623 (1)	0.0901 (3)	0.1459 (2)	0.0025 (4)	0.0000 (6)	0.0002 (5)
	MTD (↓)	1.1098 (1)	1.5512 (3)	1.3280 (2)	1.8302 (4)	2.2982 (5)	4.9378 (6)