


Modele generatywne to szeroka klasa algorytmów nauczania maszynowego, która zajmuje się modelowaniem rozkładu łącznego danych. Mówiąc ogólnie, chcemy stworzyć więcej przykładów, które są podobne do tych znajdujących się już w zbiorze danych X , ale nie identycznych do nich. Możemy zacząć od bazy zawierającej zdjęcia i próbować generować nowe obrazy. Możemy wziąć bazę danych modeli 3D rzeczywistych obiektów i wyprodukować ich odpowiedniki aby umieścić je w grach komputerowych.

Modele generatywne są jedną z najszybciej rozwijających się gałęzi sztucznej inteligencji. W ostatnich latach skonstruowano wiele modeli generatywnych, takich jak Variational AutoEncoders (VAE), Wasserstein AutoEncoder (WAE), generative adversarial networks (GAN), auto-regressive models oraz flow-based generative models.

Model generatywny oparty na architekturze autoencoder dają dobre rezultaty w praktycznych zastosowaniach, ale generują rozmyte obrazy (zwłaszcza w odniesieniu do modeli adversarialnych). Z drugiej strony modele generatywne oparte na autoencoder mają pewne zalety w stosunku do innych metod. Główną zaletą w stosunku do modeli adversarialnych jest architektura zawierająca przestrzeń ukrytą. Pozwala to na jednoczesne modelowanie różnorodności na której leżą dane i przybliżanie rozkładu prawdopodobieństwa, patrz Rys. 1.



RYSUNEK 1. Wynik modelu generatywnego na bazie danych Flickr-Faces-HQ (FFHQ) (1024×1024 pikseli). Po lewej: Interpolacje między dwoma przykładami z zestawu testowego. Środkowo: Rekonstrukcja przykładów z zestawu testowego (kolumny nieparzyste odpowiadają rzeczywistym obrazom). Po prawej: Losowe próbki otrzymane przez użycie modelu generatywnego.

Jeśli zmusimy modele generatywne oparte na architekturze autoencodera do produkcji ostrych obrazów o wysokiej rozdzielczości, wówczas takie modele staną się prawdziwą konkurencją dla metod adversarialnych. Głównym celem projektu jest dostosowanie procedury trenowania i architektury modeli generujących opartych na autoenkoderach do przetwarzania obrazów o wysokiej rozdzielczości i generowania ostrych obrazów.

W szczególności chcemy skupić naszą uwagę na następujących zadaniach naukowych:

- (1) Projektowanie nowych modeli generatywnych.
- (2) Dostosowanie strategii trenowania i architektury modeli opartych na autoenkoderach tak aby umożliwić trening na obrazach o wysokiej rozdzielczości.
- (3) Zmiana geometrii przestrzeni ukrytej.