

МЕТОДИ ВИКОРИСТАННЯ ГЕНЕРАТИВНО-ЗМАГАЛЬНИХ НЕЙРОННИХ МЕРЕЖ

Сьогодні генеративно-змагальні мережі (Generative Adversarial Networks, GANs) широко застосовуються у якості засобів генеративного моделювання із використанням методів глибинного навчання. Постійно з'являється багато нових ідей, методів та моделей, які базуються на використанні цих мереж, розширюючи не лише технологію, а й напрями її застосування [1]. Метою роботи є дослідження методів, які базуються на використанні генеративно-змагальних нейронних мереж. Об'єктом дослідження є процес впровадження та використання генеративно-змагальних нейронних мереж. Предметом – моделі і методи використання цих мереж.

Зазвичай застосовуються дві мережі, одна нейронна мережа є генератором та генерує нові екземпляри даних, а інша є дискримінатором, вона оцінює їх на справжність (рис.1). Тобто, дискримінатор перевіряє кожен екземпляр даних на відношення його до набору заданих «справжніх» даних. Його метою є розпізнавання справжніх екземплярів із набору справжніх даних.




Рисунок 1 – Алгоритм роботи GAN на прикладі рукописних чисел

За створення нових зображень відповідає генератор. Він передає ці зображення дискримінатору сподіваючись, що той їх прийме справжніми. Мета генератора, наприклад, згенерувати рукописні цифри, які будуть пропущені дискримінатором. А метою дискримінатора є визначення, чи є це зображення справжнім. GAN зазвичай складна та вимоглива до обчислювальних ресурсів та вимагає ретельного налаштування параметрів для досягнення бажаних результатів. Однак вона демонструє гарну

функціональність при створенні реалістичних зображень та відновлення інших типів даних [2].

GAN працює за наступною схемою: генератор отримує випадкове число та формує зображення; згенероване зображення надсилається у дискримінатор із потоком зображень, взятих із фактичного набору даних; дискримінатор приймає як реальні, так і підроблені зображення і повертає ймовірності числа від 0 до 1 (1 ідентифікує справжнє зображення, а 0 ні) (рис.2).




Рисунок 2 – Універсальний алгоритм роботи GAN

Таким чином маємо подвійний цикл зворотного зв'язку: дискримінатор перебуває у циклі із достовірними зображеннями; генератор перебуває у циклі разом із дискримінатором. Далі наведено приклад мережі GAN, яка використовує дискримінатор та генератор:

```

import pandas as pd
import os
from keras.optimizers import Adam
df_celeb = pd.read_csv('list_attr_celeba.csv')
TOTAL_SAMPLES = df_celeb.shape[0]
SPATIAL_DIM = 64
LATENT_DIM_GAN = 100
FILTER_SIZE = 5
NET_CAPACITY = 16
BATCH_SIZE_GAN = 32
PROGRESS_INTERVAL = 80
ROOT_DIR = 'visualization'
if not os.path.isdir(ROOT_DIR): os.mkdir(ROOT_DIR)
def construct_models(verbose=False):
    discriminator = build_discriminator(NET_CAPACITY, SPATIAL_DIM,
FILTER_SIZE)
    discriminator.compile(loss='binary_crossentropy',
optimizer=Adam(lr=0.0002), metrics=['mae'])
    generator = build_generator(NET_CAPACITY, FILTER_SIZE,
LATENT_DIM_GAN)
    ### DCGAN
    gan = Sequential()
    gan.add(generator)
    gan.add(discriminator)
  
```

```

discriminator.trainable = False
gan.compile(loss='binary_crossentropy',
optimizer=Adam(lr=0.0002), metrics=['mae'])
if verbose:
    generator.summary()
    discriminator.summary()
    gan.summary()
return generator, discriminator, gan
generator_celeb, discriminator_celeb, gan_celeb =
construct_models(verbose=True)

```

Мережа дискриміраторів є стандартною згортковою мережею, яка може класифікувати зображення за допомогою біномного класифікатора (алгоритм машинного навчання, що використовується для вирішення задачі класифікації та працює з двома можливими варіантами класів: позитивним і негативним), який розпізнає зображення як реальні або як підробку [3].

Deep Convolutional GAN є нейронною мережею, яка теж використовується для генерації зображень за допомогою глибокого навчання. Вона використовує згорткові нейронні мережі для отримання функціональних параметрів зображення. Кожен шар у мережі містить згортковий шар, шар нормалізації та шар активації. Генеративна мережа використовує транспоновані згорткові шари для створення зображень. DCGAN може генерувати зображення з високою роздільною здатністю та високою якістю, це робить її корисною для застосування у різних сферах, включаючи комп'ютерний зір, медичну діагностику та ігрову індустрію. Однією з основних переваг DCGAN є те, що вона може генерувати нові зображення без необхідності мати доступ до великої кількості реальних даних [2]. Однак GAN не позбавлена недоліків. Вона може страждати від проблем із генеруванням неприродних об'єктів та тенденції до перенавчання. Крім того, GAN може бути чутливим до вибору гіперпараметрів і вимагати великої кількості даних для навчання.

Висновок. У ході дослідження розглянуто можливості та обмеження, пов'язані з використанням глибоких згорткових GAN (DCGAN) в задачах генерації зображень на прикладі рукописних чисел з набору даних MNIST та сформоване просте пояснення їх роботи. В цілому, GAN є потужним інструментом для генерації нових даних і розвитку машинного навчання.

СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ

1. Foster D. Generative deep learning: teaching machines to paint, write, compose, and play. – O'Reilly Media, 2019. – 303 p.
2. Radford A. Unsupervised representation learning with deep convolutional generative adversarial networks /A. Radford, L. Metz, S. Chintala //arXiv preprint arXiv:1511.06434. – 2015.

3. Bengio Y. Deep learning / Y. Bengio, I. Goodfellow, A. Courville. – Cambridge, MA, USA: MIT Press, 2017. – T. 1. – 686 p.