

ТЕОРИЯ ИГР В ОБУЧЕНИИ ГЕНЕРАТИВНО-СОСТЯЗАТЕЛЬНЫХ СЕТЕЙ

Рассматривается применение теории игр в обучении генеративно-состязательных сетей. Игровая постановка обучения описывается как математический фундамент развития генеративных моделей.

Введение

Генеративные модели представляют собой класс моделей машинного обучения, предназначенных для синтеза новых объектов, неотличимых от реальных данных. Обучение связано с подбором стратегии, которая определяет правила генерации, поэтому использование идей теории игр позволяет описать обучение как взаимодействие нескольких участников с различными целями и формирует математическую основу генеративно-состязательного подхода.

1. Архитектура GAN

Генеративно состязательная сеть (GAN) включает две нейронные сети, которые обучаются одновременно в режиме конкуренции [1].




Рис. 1 – Архитектура GAN

Генератор G принимает случайный вектор $z \sim p_z$ и преобразует его в синтетический объект $G(z)$, стремясь приблизить генерируемое распределение p_g к реальному распределению p_{data} . Дискриминатор получает на вход либо реальный объект $x \sim p_{data}$, либо синтетический объект $G(z)$ и оценивает вероятность принадлежности входа реальному распределению, возвращая значение $D(x) \in [0, 1]$.

II. Игровая модель обучения GAN

Обучение формулируется как игра с нулевой суммой, в которой выигрыш генератора равен проигрышу дискриминатора [2].

Целевая функция записывается в виде задачи минимакса:

$$\min_G \max_D V(D, G) = \mathbb{E}_x [\log D(x)] + \mathbb{E}_z [\log (1 - D(G(z)))] \quad (1)$$

Дискриминатор максимизирует значение данной функции и улучшает способность различать ре-

альные и синтетические объекты. Генератор минимизирует тот же функционал и повышает правдоподобие синтезируемых данных, уменьшая способность дискриминатора отличать их от реальных.

Теоретически устойчивым состоянием такой игры является равновесие Нэша, при котором ни один участник не может улучшить свой результат при фиксированной стратегии другого участника. Для фиксированного генератора оптимальный дискриминатор имеет вид:

$$D_G^*(x) = p_{data}(x) / (p_{data}(x) + p_g(x)) \quad (2)$$

Подстановка выражения в целевую функцию показывает, что задача генератора сводится к минимизации расходимости Дженсена-Шеннона между p_{data} и p_g , которая обращается в нуль, когда $p_g = p_{data}$. Равновесие Нэша в данной игре соответствует совпадению генерируемого и реального распределений.

На практике достижение устойчивого равновесия Нэша часто осложняется проблемами mode collapse и исчезающих градиентов, что приводит к нестабильности обучения и требует применения дополнительных методов регуляризации стратегий обоих игроков.

III. Выводы

Теория игр задает математическую основу генеративно-состязательных сетей, поскольку обучение формулируется как минимакс взаимодействие генератора и дискриминатора в игре с нулевой суммой. Такая постановка описывает идеальное состояние модели через равновесие Нэша и служит основой для последующих модификаций архитектур и методов стабилизации обучения генеративных моделей.

1. Goodfellow, I., Pouget-Abadie, J., Mirza, M. et al. Generative Adversarial Nets // Advances in Neural Information Processing Systems. – 2014. – Vol. 27. – P. 2672-2680.
2. Osborne, M. J., Rubinstein, A. A Course in Game Theory. – MIT Press, 1994.

Земляник Руслана Владимировна, студентка кафедры информационных технологий автоматизированных систем БГУИР, rzemlanik@gmail.com.

Научный руководитель: Протченко Екатерина Владимировна, Старший преподаватель кафедры информационных технологий автоматизированных систем БГУИР, protchenko@bsuir.by.