

УДК 004.032.26

АЛГОРИТМ МИНИМИЗАЦИИ АРТЕФАКТОВ В МНОГОМЕРНЫХ GAN-АРХИТЕКТУРАХ С ПРИМЕНЕНИЕМ ИТЕРАТИВНОГО РЕГУЛИРУЕМОГО РАСПРЕДЕЛЕНИЯ ВЫБОРОК

Ковбаса Г.А., аспирант

Белорусский государственный университет информатики и радиоэлектроники
г. Минск, Республика Беларусь

Азаров И.С. – д-р. техн. наук, профессор

Аннотация. Данная работа посвящена алгоритму, решающему проблему дистрибутивной точности в многоуровневых GAN. Алгоритм базируется на циклическом механизме адаптивного вероятностного сэмплирования (AIS) и системе межуровневой обратной связи (Feedback GAI) для динамической коррекции градиентного поля. В отличие от традиционных подходов, AIS интегрируется непосредственно в тренировочный цикл для динамической коррекции градиентного поля через аппроксимацию плотности данных (Density Ratio Estimation). Экспериментальные данные показали превосходство над другими многоуровневыми архитектурами GAN и адаптированными архитектурами (U-Net + GAI), увеличив логарифмическое правдоподобие на 22%.

Ключевые слова. Генеративно-состязательные сети, адаптивное вероятностное сэмплирование (AIS), Feedback GAI, аппроксимация плотности данных (Density Ratio Estimation).

В области глубокого генеративного моделирования ключевой задачей остается достижение высокой точности воспроизведения сложных морфологических структур данных при сохранении статистической устойчивости процесса обучения. Традиционные методы минимизации дивергенций зачастую фокусируются на поверхностных визуальных признаках, игнорируя глубинные топологические свойства целевого распределения [1].

Целью настоящей работы является формализация и реализация алгоритма, который за счет взвешенного градиентного спуска позволяет генератору игнорировать зоны «псевдореализма» и фокусироваться на восстановлении инвариантных морфологических структур [2]. Такой подход обеспечивает теоретически обоснованную сходимости к истинному распределению данных в условиях ограниченности выборки и высокой сложности целевой топологии.

Для преодоления этих ограничений мы перешли к парадигме имитационного обучения (GAI), рассматривая генератор как агента, адаптирующего текущие условия обучения сети в соответствии с показателями оценки распределения данных [2]. Однако для обеспечения истинной дистрибутивной точности потребовался переход от простой имитации к статистическому выравниванию многообразий на каждом шаге итерации с учетом AIS [3].

Таким образом, алгоритм минимизации артефактов в многомерных GAN-архитектурах с применением итеративного регулируемого распределения выборок можно описать как последовательные итерации со следующими действиями:

1. Этап инициализации и дискриминации:
 - Обучение сети дискриминатора.
 - Вычисление density ratio estimation: на основе выхода сигмоиды дискриминатора будет получено отношение плотностей распределения реальных данных к плотности распределения данных с текущих выходов, называемое $g(x)$.
2. Формирование энергетического суррогата:
 - Вместо сложного вычисления якобиана (который требует много ресурсов), вводится функция энергии, энергетический суррогат, то есть функциональное представление отношения плотностей, описанных на предыдущем шаге.
3. Работа с proposal distribution:
 - Цикл обновления: каждые $k = 10$ итераций производится обновление параметров proposal distribution $q(z)$, вспомогательного распределения, которое используется для аппроксимации целевого (истинного) распределения.
 - Взвешенная выборка: используются текущие веса для корректировки параметров для соответствия областям с высокой плотностью реальных данных [4].
4. Расчет Importance Weights:
 - Производится расчет весов для каждого сгенерированного батча.
5. Градиентное обновление генератора. Процедура расчета градиента принимает на вход три ключевых компонента:
 - Латентные векторы.
 - Энергетические оценки. Значения логитов, полученные от дискриминатора для текущего батча сгенерированных образов.

– Логарифм плотности proposal distribution.

Рассмотрим упомянутые выше процедуры алгоритма с точки зрения регуляции распределений.

Density Ratio Estimation (DRE):

Использование отношения плотностей вместо простых бинарных меток — это переход от классификации к байесовскому выводу. Формула математически выводится из оптимального дискриминатора и позволяет напрямую оценивать расхождение между распределениями через f -дивергенции.

Энергетический суррогат:

Под данным термином мы понимаем замену Якобиана функцией энергии благодаря чему оценка AIS получает более структурированную информацию, так как энергия $E(x)$ отражает не просто шум, а иерархическое соответствие морфологии, что делает оценку отношения плотностей более стабильной.

Вычисление логарифма детерминанта Якобиана требует кубическую сложность для полных матриц, в то время как скалярная функция энергии дифференцируется за $O(n)$, что делает алгоритм масштабируемым для глубоких сетей.

Annealed Importance Sampling:

Метод Annealed Importance Sampling считается «золотым стандартом» для оценки логарифма правдоподобия в моделях с ненормированной плотностью (энергетических моделях) [5]. Введение весов $w(x)$ корректирует смещение выборки, что гарантирует сходимость к истинному распределению. Процесс последовательного приближения в методе AIS требует определения оптимального графика изменения параметра связи [5].

Вместо тривиального линейного приращения рекомендуется использовать нелинейные последовательности (например, геометрические). Математическое обоснование заключается в том, что в зонах высокого расхождения между предлагающим и целевым распределениями требуется более дискретное и детальное описание промежуточных состояний [6]. Слишком резкое изменение параметра ведет к резкому росту дисперсии Importance Weights: статистическая значимость концентрируется в единичных выборках, что обесценивает вклад остального набора данных и дестабилизирует оценку градиента.

Так как данное решение реализовано при помощи Python с применением PyTorch необходимо учесть следующие особенности реализации, обусловленные как итерационным подходом [7], так и выбора средств реализации.

В классических состязательных моделях дискриминатор функционирует как вероятностный классификатор. Однако для корректного вычисления отношения плотностей $p(z)$ целесообразно использовать значения функции до применения нелинейного сжимающего преобразования (сигмоиды) [6]. Это позволяет оперировать в пространстве логитов, что математически эквивалентно логарифму отношения вероятностей.

Такой подход обеспечивает вычислительную стабильность: исключается риск деления на исчезающе малые величины и предотвращается насыщение градиента, когда модель достигает высокой степени уверенности в классификации. Энергия в данном контексте становится линейной мерой правдоподобия, обеспечивая более плавную траекторию сходимости.

Регулярное обновление параметров proposal distribution через каждые K итераций является ключевым механизмом используемым для имплементации адаптивного сэмплинга. Параметр K определяет баланс между актуальностью модели и её устойчивостью к локальным флуктуациям.

Для предотвращения стохастических осцилляций целесообразно применять метод экспоненциального сглаживания параметров. Это создает необходимую инерцию в обучении: морфологический фокус системы смещается плавно, позволяя генератору последовательно осваивать сложные структурные признаки, не теряя при этом ранее полученную информацию о глобальной топологии данных [8,9].

В качестве экспериментальных данных представлены следующие модели для сравнительных оценок:

Архитектуры моделей для сравнения:

1. Базовый GAN: DCGAN [8,9].
2. NA-GAN [10].
3. U-Net GAI: модифицированная версия U-Net GAN с учетом имитационного обучения [11].

Предлагаемая модель:

1. Техническое описание параметров нейросетевой архитектуры.
2. Глубина генератора: 9 слоев.
3. Глубина дискриминатора: 10 слоев.
4. Размерность латентного пространства: 256.
5. Адаптивная смесь Gaussian Mixture Model (GMM).
6. Параметры AIS: 20 промежуточных итераций в рамках одного цикла отжига, выполняемого с периодичностью в 10 шагов градиентного обновления.

7. Размер микро-батча (выборки): 16.
8. Количество итераций обучения: 1,1 млн итераций.

Таблица 1 – Сравнительные показатели тестирования моделей

№п/п	Метод	FID ↓	Log-Likelihood (AIS) ↑
1	Базовый GAN	32.5	-482.1
2	HA-GAN	21.3	-395.4
3	U-Net GAI	18.8	-385.1
4	Адаптированная модель с предлагаемым алгоритмом	11.6	-297.4

Таким образом был разработан алгоритм циклической интеграции AIS через Density Ratio Estimation, основным преимуществом которого является минимизация потери многообразия распределения признаков в выходных данных, что снижает риски появления артефактов коллапса мод в итоговом распределении. Разработанный подход рекомендуется для построения систем генерации изображений высокой точности и проектирования цифровых двойников сложных технических объектов.

Список использованных источников:

1. *Intriguing Properties of Modern GANs* [Электронный ресурс] // *arXiv*. – Режим доступа: arxiv.org. – Дата доступа: 01.03.2026.
2. *Generative Adversarial Imitation Learning* [Электронный ресурс] // *Emergent Mind*. – Режим доступа: emergentmind.com. – Дата доступа: 01.03.2026.
3. *Adaptive importance sampling via auto-regressive generative models and Gaussian processes* [Электронный ресурс] / L. Zhang [et al.] // *PMC*. – Режим доступа: <https://pmc.ncbi.nlm.nih.gov/articles/PMC8475780/>. – Дата доступа: 01.03.2026.
4. *LayerSync: Self-aligning Intermediate Layers* [Электронный ресурс] // *arXiv*. – Режим доступа: arxiv.org. – Дата доступа: 01.03.2026.
5. *Adaptive Importance Sampling and Quasi-Monte Carlo Methods for 6G URLLC Systems* [Электронный ресурс] // *ResearchGate*. – Режим доступа: researchgate.net. – Дата доступа: 01.03.2026.
6. *Pseudo-Contrast-enhanced US via Enhanced Generative Adversarial Networks for Evaluating Tumor Ablation Efficacy* [Электронный ресурс] // *Radiology: Artificial Intelligence*. – Режим доступа: rsna.org. – Дата доступа: 01.03.2026.
7. *Choi, J. DPAIL: Training Diffusion Policy for Adversarial Imitation Learning without Policy Optimization* [Электронный ресурс] / J. Choi // *KAIST AIPR Lab*. – Режим доступа: kaist.ac.kr. – Дата доступа: 01.03.2026.
8. *Two-flow Feedback Multi-scale Progressive Generative Adversarial Network* [Электронный ресурс] // *arXiv*. – Режим доступа: arxiv.org. – Дата доступа: 01.03.2026.
9. *Collaborative-GAN: An Approach for Stabilizing the Training Process of Generative Adversarial Network* [Электронный ресурс] // *ResearchGate*. – Режим доступа: researchgate.net. – Дата доступа: 01.03.2026.
10. *Hierarchical Amortized GAN for 3D High Resolution Medical Image Synthesis* [Электронный ресурс] // *ResearchGate*. – Режим доступа: researchgate.net. – Дата доступа: 01.03.2026.
11. *Ковбаса, Г Learning to Synthesize: GAN Optimization with Imitation and Distribution Feedback* / Г. Ковбаса // *Pattern Recognition and Information Processing (PRIP'2025) : Proceedings of the 17th International Conference, Minsk, 16–18 Sept. 2025 / UIIP NASB ; [editorial board: V. I. Ivin (chair) et al.]*. – Minsk : UIIP NASB, 2025. – P. [451-453].

UDC 004.032.26

ARTIFACT MINIMIZATION ALGORITHM IN MULTIDIMENSIONAL GAN ARCHITECTURES USING ITERATIVE REGULATED SAMPLE DISTRIBUTION

Kovbasa G.A., graduate student

Belarusian State University of Informatics and Radioelectronics¹, Minsk, Republic of Belarus

Azarov E.S. – Doctor of Technical Sciences

Annotation. This paper presents an algorithm that addresses the problem of distributed accuracy in multilayer GANs. The algorithm is based on a cyclical adaptive probability sampling (AIS) mechanism and a cross-layer feedback system (GAI) for dynamic gradient field correction. Unlike traditional approaches, AIS is integrated directly into the dynamic gradient field correction workflow through density approximation (Density Ratio Estimation). Experimental data demonstrated superiority over other multilayer GAN architectures and adapted architectures (U-Net + GAI), increasing the log-likelihood by 22%.

Keywords. Generative adversarial networks, adaptive probability sampling (AIS), Feedback GAI, Density Ratio Estimation.