

doi: 10.17586/2226-1494-2025-25-1-87-94

УДК 004.852

Создание модельных наборов целевых классов DAS-сигналов с использованием технологии генеративных состязательных нейронных сетей

Андрей Владимирович Тимофеев✉

ТОО «Эквалайзум», Астана, 010000, Казахстан

timofeev.andrey@gmail.com✉, <https://orcid.org/0000-0001-7212-5230>

Аннотация

Введение. Предложен новый метод генерации модельных наборов (Distributed Acoustic Sensing, DAS) сигналов различных классов. Статистические характеристики модельных сигналов аналогичны реальным DAS-сигналам соответствующих классов и могут быть использованы для повышения качества обработки DAS-сигналов методами машинного обучения. **Метод.** Представленный метод состоит в модификации технологии генеративных состязательных сетей (Generative Adversarial Network, GAN). Новизна подхода заключается во введении дополнительного контура внешнего контроля эффективности генеративной сети, который включает классификатор, обученный на доступном (малом) корпусе реальных DAS-сигналов. **Основные результаты.** Предложен оригинальный метод генерации модельных наборов DAS-сигналов, основанный на технологии GAN, и отличающийся от классической технологии наличием дополнительного контура внешнего контроля качества. Сформулирован критерий оптимальности генерирующей системы, который достигается путем пошагового реконфигурирования нейросетевой структуры GAN. Реконфигурирование основано на методе оптимизации Нелдера–Мида. Разработана и исследована на реальных данных программная реализация предложенного метода на платформе Python. Приведены результаты, доказывающие практическую эффективность рассмотренного подхода. Использование метода позволило увеличить мощность обучающего корпуса данных и, тем самым, повысить результирующую надежность классификации целевых DAS-сигналов. **Обсуждение.** Разработанный подход перспективен для применения в тех случаях, когда емкость представленных для обучения корпусов данных недостаточна для обеспечения высоконадежной классификации.

Ключевые слова

GAN, машинное обучение, классификация, оптоволоконная система мониторинга, DAS, генеративная модель

Ссылка для цитирования: Тимофеев А.В. Создание модельных наборов целевых классов DAS-сигналов с использованием технологии генеративных состязательных нейронных сетей // Научно-технический вестник информационных технологий, механики и оптики. 2025. Т. 25, № 1. С. 87–94. doi: 10.17586/2226-1494-2025-25-1-87-94

DAS signal modeling using the generative adversarial neural network technique

Andrey V. Timofeev✉

Equalizum LLP, Astana, 010000, Kazakhstan

timofeev.andrey@gmail.com✉, <https://orcid.org/0000-0001-7212-5230>

Abstract

A new method of generating model sets of Distributed Acoustic Sensing (DAS) signals of different classes is proposed. Statistical characteristics of model signals are quite similar to real DAS-signals of corresponding classes and can be used for sharp improvement of DAS-signals processing quality by machine learning methods. The proposed method is a modification of the Generative Adversarial Network (GAN) technique. The novelty of the approach lies in the introduction of an additional external control loop for the performance of the generative network which includes a classifier trained on an available (small) corpus of real DAS signals. A method for generating model sets of DAS signals based on GAN technology is proposed, and it differs from the classical technology by the presence of an additional

external quality control loop. An optimality criterion for the generating system is formulated, the optimum of which is achieved by step-by-step reconfiguration of the GAN neural network structure. Reconfiguration is based on the Nelder-Mead optimization method. A software implementation of the proposed solution architecture on the Python platform is developed and tested on real data. Results are presented proving the practical efficiency of the proposed method. In particular, the proposed method allowed to increase the capacity of the training dataset and, thus, to increase the resulting reliability of the classification of target DAS signals. The developed approach is promising for use in cases where the capacity of the datasets provided for training is insufficient to ensure highly reliable classification.

Keywords

GAN, machine learning, classification, fiber optic monitoring system, DAS, generative model

For citation: Timofeev A.V. DAS signal modeling using the generative adversarial neural network technique. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2025, vol. 25, no. 1, pp. 87–94 (in Russian). doi: 10.17586/2226-1494-2025-25-1-87-94

Введение

Системы Coherent Optical Time Domain Reflectometer (C/F-OTDR) [1–3] широко используются для комплексного мониторинга протяженных объектов, например, для контроля текущего состояния трубопроводных систем. C/F-OTDR-системы также называются системами распределенного акустического зондирования (Distributed Acoustic Sensing, DAS) мониторинга. DAS используют виброчувствительность потока инфракрасной энергии, который генерируется полупроводниковыми, высококогерентными лазерами и передается через оптоволокно в импульсном режиме. DAS-системы могут быть применены для мониторинга различных физических явлений, таких как вибрации и акустические сигналы, что делает их полезными в различных областях, включая безопасность, мониторинг протяженной инфраструктуры и научные исследования, например, сейсмологические. Одной из важных и довольно сложных задач акустического мониторинга данного типа является не только регистрация полезного сигнала, но и его последующая, эффективная обработка с целью выделения информативной составляющей, необходимой для решения прикладных задач контроля и диагностики состояния контролируемого объекта. На практике DAS-системы способны эффективно контролировать виброакустическое поле объекта мониторинга в частотном диапазоне [0, 500] Гц. Основными задачами DAS-систем является обнаружение и классификация целевых, виброакустических сигналов, которые представляют собой крайне редкие явления и принимаются на фоне широкополосного, нестационарного помехового процесса. Решение о типе обнаруженного сигнала принимается подсистемой классификации, которая основана на методах машинного обучения (Machine Learning, ML) [1]. Подсистему классификации условимся называть ML-классификатором. Сигналы, генерируемые C/F-OTDR-системой, относятся к классу нестационарных, широкополосных шумоподобных сигналов [1]. Их нестационарность и шумоподобность определяется множеством факторов, основными из которых являются следующие: нестационарность динамики виброакустического поля объекта; особенности принимаемого канала C/F-OTDR-системы [1]. Например, нестационарность виброакустического поля трубопроводной системы, предназначенной для отвода шахтных вод, определяется динамикой процесса перекачки жидкости и технологическим режимом перекачки (давление

и скорость движения жидкости внутри трубопровода). В системах данного типа движение жидкости по трубопроводу практически никогда не носит ламинарный характер, наоборот, в данном случае, это движение практически всегда представляет собой турбулентный процесс [4], параметры которого зависят от геометрии трубопровода, давления, плотности и угла напора перемещаемой жидкости. Как результат, виброакустическое поле трубопроводной конструкции, измеряемое посредством C/F-OTDR-системы, имеет ярко выраженный нестационарный, шумоподобный характер [4]. Одна из основных проблем, возникающая при классификации сигналов в C/F-OTDR-системах на практике – проблема критической малости мощности доступных для исследования сигналов целевого типа. Отметим, что данная проблема отсутствует для «фоновых» сигналов, но полученных записей образцов целевых сигналов, с целью обнаружения которых реализуется виброакустический мониторинг объекта, практически всегда недостаточно для полноценного обучения ML-классификатора. Описанная проблема обусловлена тем, что проведение натуральных экспериментов, например, на эксплуатируемом трубопроводе, с целью имитации утечки, представляет собой дорогостоящий, часто практически невозможный процесс. Например, в условиях Крайнего Севера, при температуре окружающей среды минус 50 °С и давлении в трубопроводной системе более 20 бар, создание множества сигналов утечки транспортируемого агента с целью пополнения обучающего набора сигнальных образцов при помощи имитатора отверстия в стенке трубопроводной конструкции сопряжено с технологическими рисками, значительными организационными и материальными издержками. На такие издержки эксплуатирующая трубопровод организация пойти не может.

Таким образом, разработчик C/F-OTDR-систем мониторинга сталкивается с ситуацией дефицита имеющихся в его распоряжении образцов целевых сигналов, например, сигналов от утечек транспортируемого по трубопроводной системе агента.

Существует несколько способов решения проблемы малой мощности доступного для исследования корпуса данных, одним из которых является искусственная генерация множества сигналов, эффективно имитирующих сигналы целевые. В настоящей работе предложено решение данной проблемы на базе оригинальным образом модифицированной технологии генеративно-состязательных нейронных сетей (Generative

Adversarial Network, GAN). Также представлена новая схема генерации имитационных сигналов.

Генеративно-сопоставительные нейронные сети

GAN предназначена для генерации стохастических объектов подобным объектам, которые исходно представлены в доступном «эталонном» множестве X . Впервые эта модель была предложена в работе [5], развита в [6, 7] и множестве других. Фактически, GAN представляет собой алгоритм машинного обучения без учителя, основанный на связанной комбинации из двух нейронных сетей. Одна из этих сетей, называемая генеративной моделью (генератором), генерирует образцы, которые имитируют эталонные образцы из X . Другая из этих сетей называется дискриминатором и предназначена для проверки того, насколько образцы, созданные генератором, похожи на образцы из эталонного множества X . В процессе генерации используются случайные наборы из, так называемого, «латентного пространства», которое, по сути, представляет собой некое случайное поле ограниченной размерности. Размерность этого поля входит в множество гиперпараметров GAN. Согласно идее, заложенной в GAN, генератор получает случайные векторы из этого латентного пространства и преобразует их в имитационные образцы, степень похожести которых на образцы из X , собственно, и определяет дискриминатор. Дискриминатор обучается различать подлинные и сымитированные образцы, а результаты дискриминации подаются на вход генератора для того, чтобы генератор имел возможность, в процессе конкурентного обучения, выбрать оптимальный набор латентных параметров. В результате, целью генератора является максимальное повышение процента ошибок дискриминатора. И наоборот, целью дискриминатора является максимальное повышение надежности распознавания сымитированного образца. В рамках концепции GAN, в процессе совместного

конкурентного обучения, генератор и дискриминатор должны достигнуть некоего сбалансированного состояния. Сбалансированность в контексте GAN подразумевает то, что генератор и дискриминатор достигли такого состояния, в котором генератор способен создавать убедительные имитации объектов из эталонного класса X , а дискриминатор способен эффективно отличать эти имитации от образцов из X . В этом случае говорят о минимаксном состоянии равновесия по Нэшу, в рамках которого генератор и дискриминатор достигли определенно высокого уровня качества. В этом случае GAN представляет собой игру с нулевой суммой между двумя игроками — генератором и дискриминатором. Обобщенная схема GAN представлена на рис. 1.

Упрощенно, общий алгоритм обучения GAN можно представить последовательностью этапов.

Этап 1. Инициализация. На этом этапе инициализируются генератор и дискриминатор. Генератор стартует со случайной инициализации, а дискриминатор может быть инициализирован с помощью любой модели, которая способна различать реальные и сгенерированные данные.

Этап 2. Обновление генератора. Генератор создает набор данных, а затем эти данные подаются на вход дискриминатору. Дискриминатор оценивает, насколько хорошо сгенерированные данные соответствуют реальным данным. Затем эта оценка используется для обновления весов генератора. Цель генератора — получить высокую оценку от дискриминатора.

Этап 3. Обновление дискриминатора. После обновления генератора дискриминатор получает новые сгенерированные данные, а также фрагмент X . Дискриминатор оценивает, насколько хорошо сгенерированные данные соответствуют реальным данным. Затем эта оценка используется для обновления весов дискриминатора. Цель дискриминатора — получить высокую оценку для реальных данных и низкую оценку для сгенерированных данных.

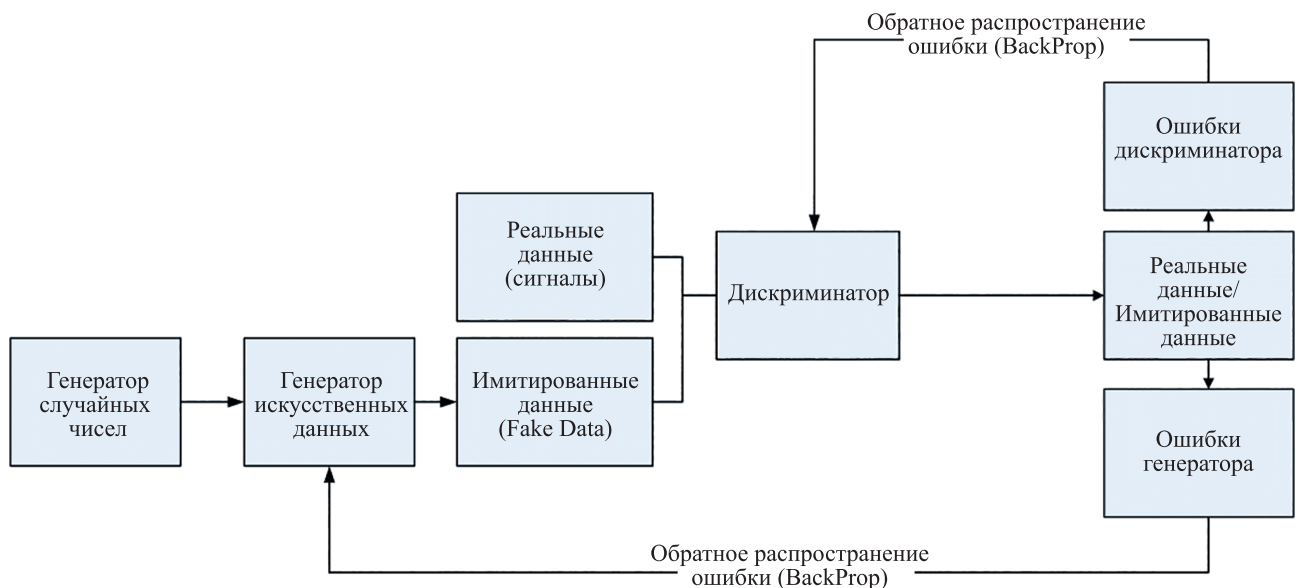


Рис. 1. Обобщенная схема GAN

Fig. 1. Generalized scheme of GAN

Этап 4. Итеративный процесс. Этапы 2 и 3 повторяются до тех пор, пока не будет достигнуто желаемое качество сгенерированных данных.

Обозначения и формальная постановка задачи

Пусть $X \subseteq R^m$ — множество шумоподобных, димантических C/F-OTDR-сигналов длительностью t_k , соответствующих K классам X_k , причем $X = \bigcup_{k \in K} X_k$;

$\bigcap_{k \in K} X_k = \emptyset$; R^m — m -мерное евклидово пространство.

Для каждого $k \in K$ на вероятностных пространствах Ω и Θ заданы величины $\mathbf{x}^{(k)} \in R^n$ и $\mathbf{z}^{(k)} \in R^m$ с плотностями распределений $p_k(\mathbf{x}^{(k)})$ и $\lambda_k(\mathbf{z}^{(k)})$ вида:

$$\begin{aligned} \mathbf{x}^{(k)}: \Omega &\rightarrow X_k, \mathbf{x}^{(k)} \sim p_k(\mathbf{x}^{(k)}); \exists i: X_k \subseteq X, \\ \mathbf{z}^{(k)}: \Theta &\rightarrow X_k, \mathbf{z}^{(k)} \in Z \subseteq R^n, \mathbf{z}^{(k)} \sim \lambda_k(\mathbf{z}^{(k)}), \\ k \in K &\exists: \left(X_k^{(L)} \subseteq X_k, |X_k^{(L)}| = N \right), \end{aligned}$$

где $X_k^{(L)}$, $k \in K$ — априорно заданные множества реальных, «эталонных» образцов сигналов.

Рассмотрим функции $D_k: X \rightarrow [0, 1]$, $k \in K$, $D_k(\mathbf{x}) = \overline{P}_k(\mathbf{x} \in X_k)$, $\overline{P}_k(\mathbf{x} \in X_k)$ — оценка вероятности того, что $\mathbf{x} \in X_k$, при этом, в общем случае, $\overline{P}_k(\mathbf{x} \in X_k) \neq P_k(\mathbf{x} \in X_k)$, где $P_k(\mathbf{x} \in X_k)$ — истинная вероятность $\mathbf{x} \in X_k$. Так как $p_k(\mathbf{x}^{(k)})$, $k \in K$, неизвестны, поэтому также неизвестны и $P_k(\mathbf{x} \in X_k)$. Функции $\{D_k | k \in K\}$ называются *дискриминаторами* для классов $\{X_k\}$. Для каждого $k \in K$ существует, но неизвестен, идеальный дискриминатор $D_k^*: X \rightarrow [0, 1]$ такой, что $D_k^* = P_k(\mathbf{x} \in X_k)$. Рассмотрим функции $\{G_k\}$ такие, что $\forall k \in K: G_k: Z \rightarrow X_k$. Согласно этому определению, конкретная функция G_k , принимаемая в качестве аргумента случайный вектор $\mathbf{z}^{(k)} \in Z$, генерирует образец $G_k(\mathbf{z}^{(k)}) \in X_k$.

Для каждого $k \in K$ классическая Vanilla GAN [5, 6] состоит из двух компонентов: G_k и D_k . Функционально, G_k получает на вход $\mathbf{z}^{(k)}$ и пытается преобразовать эти величины в m -векторы, которые выглядят как обучающие данные из $X_k^{(L)}$. С другой стороны, D_k пытается отличить эти векторы от обучающих данных из $X_k^{(L)}$.

Очевидно, что оптимальный генератор G_k^* удовлетворяет следующему равенству:

$$\begin{aligned} G_k^* &= \text{ArgMax}_{G_k} [P_k(G_k(z) \in X_k) \lambda_k(z) dz = \\ &= \text{ArgMax}_{G_k} [D_k^*(G_k(z)) \lambda_k(z) dz. \end{aligned}$$

При условии статистической независимости наблюдений в $X_k^{(L)}$, легко видеть:

$$\begin{aligned} D_k^* &= \text{ArgMax}_{D_k} \left(E_{\mathbf{x} \sim p(\mathbf{x})} [\log D_k(\mathbf{x})] + \right. \\ &\left. + E_{\mathbf{z} \sim q(\mathbf{z})} [1 - \log D_k(G(\mathbf{z}))] \right), \end{aligned}$$

где E — символ математического ожидания.

В рамках концепции GAN [5, 6], искомые компоненты G_k и D_k определяются в результате следующей минимакс-игры между дискриминатором D_k и генератором G_k :

$$\begin{aligned} \min_{G_k} \max_{D_k} V(D_k, G_k) &= \\ &= E_{\mathbf{x} \sim p(\mathbf{x})} [\log D_k(\mathbf{x})] + E_{\mathbf{z} \sim q(\mathbf{z})} [1 - \log D_k(G_k(\mathbf{z}))]. \end{aligned} \quad (1)$$

Согласно [7], функции G_k и D_k могут быть представлены в виде нейросетей $G_k(w_G^{(k)}, \theta_G^{(k)})$ и $D_k(w_D^{(k)}, \theta_D^{(k)})$, которые зависят от наборов параметров $(w_G^{(k)}, \theta_G^{(k)})$ и $(w_D^{(k)}, \theta_D^{(k)})$ соответственно. При этом $w_D^{(k)}$, $w_G^{(k)}$ — весовые коэффициенты, настраиваемые стандартными методами *backpropagation* [8] и *stochastic gradient descent* [9], а $\theta_D^{(k)}$, $\theta_G^{(k)}$ — гиперпараметры, определяющие структуру соответствующих нейронных сетей.

В рамках настоящей работы рассматривались архитектуры $G_k(w_G^{(k)}, \theta_G^{(k)})$ и $D_k(w_D^{(k)}, \theta_D^{(k)})$ с линейным стеком слоев. Данный тип нейросети достаточен для решения поставленной задачи. Другие характеристики нейронной сети, такие как число слоев, тип слоя, количество нейронов в слоях, тип функции активации и другие были включены в набор гиперпараметров. При этом в процессе оптимизации набора гиперпараметров категориальные параметры кодировались обычным унитарным кодом (One-Hot Encoding, [10]). В этом случае решение задачи (1) будет сведено к выбору пар $(w_G^{(k)}, \theta_G^{(k)})$ и $(w_D^{(k)}, \theta_D^{(k)})$ для каждого $k \in K$.

Пусть задан классификатор $\chi(\mathbf{x} | \bigcup_{k \in K} X_k^{(L)}): X \rightarrow K$, обученный на множестве $\bigcup_{k \in K} X_k^{(L)} \subseteq X$ и для малых $\rho_k > 0$ допускающий следующую запись:

$$\forall_{k \in K} P\left(\chi\left(\mathbf{x}^{(k)} | \bigcup_{k \in K} X_k^{(L)}\right) = k\right) = 1 - \rho_k.$$

Необходимо, опираясь на обучающие множества $X_k^{(L)}$, путем выбора параметров $(w_G^{(k)}, \theta_G^{(k)})$ и $(w_D^{(k)}, \theta_D^{(k)})$, в процессе решения (1), идентифицировать структуру функций G_k и D_k таким образом, чтобы генерируемые величины $G_k(\mathbf{z}^{(k)})$ имели плотности распределения вероятностей $g_k(x)$, близкие к $p_k(x)$ по некоторой метрике $D(p_k, g_k)$ при условии

$$\forall_{k \in K} P\left(\chi\left(G_k(\mathbf{z}^{(k)}) | \bigcup_{k \in K} X_k^{(L)}\right) = k\right) \rightarrow \max. \quad (2)$$

Отметим, что в данном случае классификатор χ обеспечивает внешний контроль качества функционирования GAN.

Довольно важен вопрос о том, каким образом определяется расстояние $D(p_k, g_k)$, представляющее собой степень близости распределений $g_k(x)$ и $p_k(x)$? Например, для сравнения схожести распределений можно использовать классическую метрику Хеллингера:

$$D_H(p_k, g_k) = 1 - \int \sqrt{p_k(x)g_k(x)} dx.$$

В этом случае, чем ближе распределения p_k и g_k , тем ближе $D_H(p_k, g_k)$ к нулю. Очевидно, что

$$\begin{aligned} \left(\int p_k(x)g_k(x) dx \rightarrow \max \right) &\Rightarrow \left(\int \sqrt{p_k(x)g_k(x)} dx \rightarrow 1 \right) \Rightarrow \\ &\Rightarrow (D_H(p_k, g_k) \rightarrow 0). \end{aligned}$$

Так сложилось, что в практике GAN широко используются следующие метрики:

— метрика Кульбака–Лейблера

$$D_{KL}(p_k, g_k) = \int_X p_k(x) \log \left(\frac{p_k(x)}{g_k(x)} \right) dx;$$

— кросс-энтропия

$$H(p_k, g_k) = \int_X p_k(x) \log(g_k(x)) dx;$$

— m-метрика Вассерштейна [11]

$$W_m(p_k, g_k) = \inf_{\gamma \in \Gamma(p_k, g_k)} \left(E_{(x,y)\gamma} d(x,y)^m \right)^{1/m};$$

$\Gamma(p_k, g_k)$ — совокупность всех сдвигиваний распределений p_k, g_k , определенных в метрическом пространстве (M, d) , где M — носитель метрического пространства; $d(x, y)$ — метрика между $x, y \in M$.

Напомним, что $H(p_k, g_k) = H(p_k) + D_{KL}(p_k, g_k)$, где $H(p_k)$ — энтропия p_k .

Так как варьирование типом метрики представляется исследователям наиболее продуктивным способом развития концепта GAN, было предложено несколько очевидных модификаций GAN, в том числе: «Wasserstein GAN» [12], «Least squares GAN», «Hinge loss GAN», «InfoGAN» [13] и другие, основанные на использовании метрик $D(p_k, g_k)$ соответствующего типа. Все эти варианты GAN имеют как плюсы, так и минусы, но сама по себе проблема минимаксной оптимизации GAN из (1) до сих пор представляет собой серьезную теоретическую и практическую проблему. В частности, в [14] указывается на то, что GAN, обученные с помощью методов оптимизации первого порядка, как правило, не сходятся к равновесию Нэша. Что, впрочем, не делает эти GAN бесполезными: возможны сценарии, когда генерируемые такими GAN имитированные образцы сигналов могут быть пригодны для практического использования несмотря на то, что они не будут оптимально близки к реальным, эталонным образцам. В [14] доказано то, что GAN-игры с нулевой суммой могут не иметь равновесия Нэша и поэтому предложена другая формулировка равновесия нулевой GAN-игры с целевой функцией, заданной проксимальным оператором. Это равновесие получило название проксимального. Проксимальное равновесие отражает последовательную природу GAN, когда сначала модифицируется генератор, и только потом происходит модификация дискриминатора. В [14] строго доказано, что оптимальная генеративная модель в задачах GAN Вассерштейна обеспечивает проксимальное равновесие. В рамках концепции достижения проксимального равновесия участники игры выбирают стратегию, которая минимизирует максимально возможный убыток независимо от того, какую стратегию выберет другой участник. Различие между равновесием Нэша и проксимальным равновесием заключается в том, что равновесие Нэша фокусируется на минимизации максимального возможного убытка для каждого игрока, в то время как проксимальное равновесие фокусируется на минимизации максимального возможного убытка в общем. Для преодоления проблемы возможного «застывания» классического GAN в равновесии Нэша, в [14] предложено использовать множество генераторов, каждый из которых обучается в режиме соревнования с

другими генераторами, а не только с одним дискриминатором. Таким образом, каждый генератор обучается на основании различных стратегий, что может помочь преодолеть проблему «застывания» GAN в равновесии Нэша. Формирование стратегии, в данном случае, подразумевает использование различных архитектур сети и значений гиперпараметров.

В рамках настоящей работы использовался новый подход к формированию стратегии обучения GAN, который показал практическую приемлемость для исследуемого класса сигналов.

Метод решения

При решении поставленной задачи были учтены следующие особенности технологии GAN.

Особенность 1. Фундаментальная проблема определения универсального дискриминатора: этот компонент GAN принципиально недоступен в силу ограниченности заданного множества X .

Особенность 2. Существующая ныне неопределенность в части универсального метода оценивания эффективности GAN. В настоящее время все практически приемлемые методы оценивания качества GAN разработаны исключительно для нейронных сетей, генерирующих изображения.

Для учета особенности 1 было решено использовать дискриминатор, с приемлемым уровнем качества отделяющий элементы X от образцов, созданных генератором, т. е. определенный только на заданном множестве X . Учет особенности 2 представляет собой существенно более сложную проблему. Дело в том, что в силу динамичности C/F-OTDR-сигналов, классические метрики сходства, например, критерий согласия Колмогорова–Смирнова, T-критерий Вилкоксона, критерий Фридмана и иные, предполагающие стационарность и независимость выборок, становятся малоинформативными при сравнении распределения выборок искусственно сгенерированных векторов с выборками эталонных векторов из X .

Важно то, что сгенерированные данные предполагается использовать для обучения и тестирования подсистемы классификации C/F-OTDR-сигналов. При этом подсистема классификации C/F-OTDR-сигналов основана на использовании специального пространства признаков [1], при этом преобразование «сырых» C/F-OTDR-сигналов в пространство признаков, которое обозначим символом Δ , является существенно нелинейным. Пусть $G_k(w_G^{(k)}, \theta_G^{(k)} | \theta_D^{(k)})$ — имитация сигнала k -го класса, созданная генератором G_k , который был обучен в противодействии с дискриминатором $D_k(w_D^{(k)}, \theta_D^{(k)})$. На вход ML-классификатора $\chi[\cdot]$ поступают вектора $\Delta(G_k(w_G^{(k)}, \theta_G^{(k)} | \theta_D^{(k)}))$, при формировании которых компоненты исходных векторов $G_k(w_G^{(k)}, \theta_G^{(k)} | \theta_D^{(k)})$ используются неравномерно: одни компоненты этих векторов имеют большее влияние на $\Delta(G_k(w_G^{(k)}, \theta_G^{(k)} | \theta_D^{(k)}))$, другие — меньшее. В силу этих причин, при обучении GAN, в общем случае, нет необходимости в достижении чрезмерно малого значения $D(p_k, g_k)$. Главное, чтобы полученное распределение g_k обеспечивало выполнение условия (2). Как было отмечено, в процессе

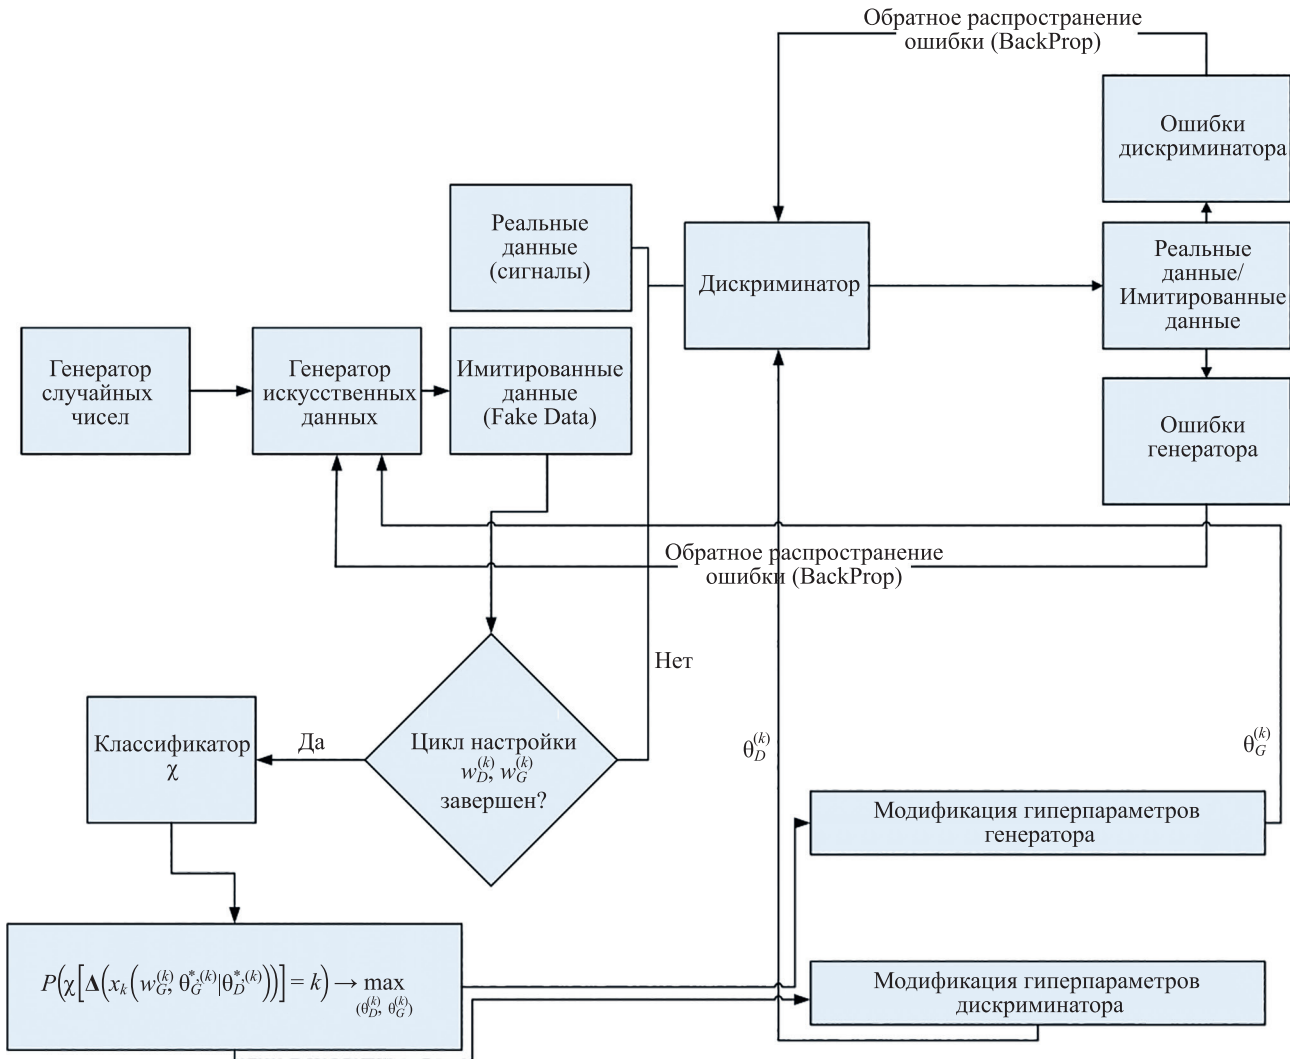


Рис. 2. Модифицированная схема GAN с «внешним» оценщиком

Fig. 2. Modified GAN scheme with an “external” estimator

обучения GAN, роль «внешнего» оценщика достигнутой эффективности GAN выполняет априорно заданный ML-классификатор χ , построенный по схеме XGBoost и обученный на множестве $\bigcup_{k \in K} X_k^{(L)}$.

Для решения поставленной задачи предлагается модифицировать схему обработки данных в контуре GAN, добавив дополнительный контур настройки гиперпараметров, основанный на использовании «внешнего» оценщика χ , что является новым подходом к формированию структуры GAN. Схематически модифицированная схема GAN приведена на рис. 2. Назначение этого контура состоит в обеспечении выбора параметров $\theta_D^{(k)}, \theta_G^{(k)}$ таким образом, чтобы выполнить условие (2).

Выбор очередных значений $\theta_D^{(k)}, \theta_G^{(k)}$ реализуется после окончания цикла настройки параметров $w_D^{(k)}, w_G^{(k)}$, которое производится стандартным методом *backpropagation*.

Принцип выбора последовательности значений $\theta_D^{(k)}, \theta_G^{(k)}$ может быть осуществлен различными способами — в настоящей работе использован принцип,

изложенный в работе [15] и основанный на поиске методом Нелдера–Мида экстремума функции, которая аппроксимирует функционал эффективности гиперпараметров. В качестве критерия эффективности, согласно постановке задачи, использовалась оценка величины $P(\chi[\Delta(G_k(w_G^{(k)}, \theta_G^{(k)} | \theta_D^{(k)}))] = k)$ для каждого $k \in K$.

В результате решения данной задачи, для каждого $k \in K$ формируются наборы гиперпараметров $(\theta_D^{*(k)}, \theta_G^{*(k)})$, для которых

$$P(\chi[\Delta(G_k(w_G^{(k)}, \theta_G^{(k)} | \theta_D^{(k)}))] = k) \rightarrow \max_{(\theta_D^{(k)}, \theta_G^{(k)})}$$

Таким образом, формируются $G_k(w_G^{(k)}, \theta_G^{*(k)})$ и $D_k(w_D^{(k)}, \theta_D^{*(k)})$, отвечающие соответствующему классу $k \in K$. Иначе говоря, для каждого класса $k \in K$ формируется отдельная GAN-схема, настроенная на генерацию сигналов именно этого класса.

Результаты построения и практического использования системы генерации данных

Для апробации предложенного метода использован набор эталонных данных, состав которого представлен в табл. 1. Как было упомянуто в разделе «Введение», статистические параметры фонового процесса зависят от конкретного участка трубопровода. Для численного исследования были взяты образцы фонового процесса (класс 0), которые соответствовали одному из участков трубопроводной конструкции, предназначенной для отвода шахтных вод. Также были использованы образцы целевых сигналов от утечки транспортируемого агента (класс 1) и образцы сигналов механического воздействия на поверхность трубопроводной конструкции (удары, класс 2). Из полученных результатов (табл. 1) следует, что целевые классы представлены сравнительно небольшим числом блоков: 160 15-секундных блоков для класса 2 и 410 таких же блоков для сигналов класса 1. Как показала практика, такой объем данных оказался недостаточным для того, чтобы обучить ML-классификатор (χ) с требуемой надежностью.

В результате предварительного обучения классификатора χ были достигнуты показатели надежности

классификации F1-меры. Необходимо было повысить показатели F1-меры для классов 1 и 2 путем использования при его дообучении данных, искусственно сгенерированных при помощи предложенной GAN-технологии.

В результате использования предложенного метода для каждого класса сигналов были созданы соответствующие им нейронные сети генератора и дискриминатора, структура которых представлена в табл. 2.

Входная размерность данных, соответствующая 15-секундному сигнальному блоку, равнялась 360, а число эпох при обучении GAN — 50. Программа для реализации предложенного метода написана на платформе Python 3.10, с использованием библиотеки Keras.

При помощи созданной GAN-системы были сгенерированы 2000 15-секундных блоков сигналов классов 1 и 2, которые были использованы при дообучении ML-классификатора.

В результате дообучения на комбинированной базе данных, состоящей как из реальных сигналов, так и из имитированных, показатель F1-меры для класса 1 повысился от уровня 0,81 до 0,95, а для класса 2 от 0,97 до 0,99.

Таблица 1. Состав набора данных

Table 1. Dataset composition

Класс сигнала	Описание класса	Число 15-секундных блоков	F1-мера
0	Фоновый сигнал	1500	0,82
1	Сигнал утечки из отверстия диаметром 10 мм	410	0,81
2	Сигнал от механического ударного воздействия на трубопроводную конструкцию	160	0,97

Таблица 2. Нейросетевая структура генератора и дискриминатора для разных классов C/F-OTDR-сигналов

Table 2. Neural network structure of generator and discriminator for different classes of C/F-OTDR signals

Класс	Генератор								Дискриминатор							
	<i>n</i>	FA	MA	<i>N</i>	FA_O	N_IN	N_O	LS	<i>n</i>	FA	MA	<i>N</i>	FA_O	N_IN	N_O	LS
0	3	Rely	U	20	TN	BN	BN	CE	3	Rely	U	10	SIG	—	—	CE
1	4	Rely	U	2560	TN	BN	BN	CE	3	Rely	U	1280	SIG	—	—	CE
2	4	Rely	U	20	TN	BN	BN	CE	3	Rely	U	10	SIG	—	—	CE

Примечание. *N* — количество нейронов в слое; *n* — количество полносвязных слоев; FA — функция активации слоя нейронной сети (для полносвязных слоев использовалась функция активации Rectified Linear Units; MA — способ инициализации весов слоя в нейронной сети (U — равномерное распределение для инициализации весов); FA_O — функция активации выходного слоя сети; N_IN — входная нормализация; N_O — выходная нормализация; LS — функция потерь (оптимальной оказалась каноническая функция бинарной кросс-энтропии, которая обозначена символом CE); BN — слой нормализации данных (BatchNormalization); TN — функция активации типа гиперболический тангенс; SIG — функция активации типа сигмоид.

Заключение

Предложенный метод генерации DAS-сигналов — универсален и может быть использован для сигналов иных типов в тех случаях, когда доступный для

обучения корпус данных недостаточен для достижения высоких характеристик качества классификации при использовании стандартных методик обучения. Исследование этих возможностей является целью дальнейших исследований.

Литература

1. Timofeev A.V., Groznov D.I. Classification of Seismoacoustic Emission Sources in Fiber Optic Systems for Monitoring Extended Objects // *Optoelectronics, Instrumentation and Data Processing*. 2020. V. 56. N 1. P. 50–60. <https://doi.org/10.3103/S8756699020010070>
2. Choi K.N., Juarez J.C., Taylor H.F. Distributed fiber optic pressure/seismic sensor for low-cost monitoring of long perimeters // *Proceedings of SPIE*. 2003. V. 5090. P. 134–141. <https://doi.org/10.1117/12.484911>
3. Zuo J., Zhang Y., Xu H., Zhu X., Zhao Z., Wei X., Wang X. Pipeline Leak Detection Technology Based on Distributed Optical Fiber Acoustic Sensing System // *IEEE Access*. 2020. V. 8. P. 30789–30796. <https://doi.org/10.1109/access.2020.2973229>
4. Тимофеев А.В., Максимов П.Н., Грознов Д.И. Применение оптоволоконной технологии для мониторинга трубопроводных систем отведения шахтных вод в криолитозоне // *Гидротехника*. 2023. № 3 (72). С. 34–43. https://doi.org/10.55326/22278400_2023_3_34
5. Goodfellow I., Pouget-Abadie J., Mirza M., Xu B., Warde-Farley D., Ozair S., Courville A., Bengio Y. Generative Adversarial Nets // *Proc. of the 28th International Conference on Neural Information Processing Systems*. 2014. V. 2. P. 2672–2680.
6. Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., Bengio, Y. Generative adversarial networks // *arXiv*. 2014. arXiv:1406.2661. <https://doi.org/10.48550/arXiv.1406.2661>
7. Goodfellow Ian. NIPS 2016 Tutorial: Generative Adversarial Networks // *arXiv*. 2017. arXiv:1701.00160. <https://doi.org/10.48550/arXiv.1701.00160>
8. Goodfellow I., Bengio Y., Courville A. Back-Propagation and Other Differentiation Algorithms // *Deep Learning*. MIT Press. 2016. P. 200–220.
9. Duchi J., Hazan E., Singer Y. Adaptive subgradient methods for online learning and stochastic optimization // *Journal of Machine Learning Research*. 2011. V. 12. P. 2121–2159.
10. Jones K.S. A Statistical interpretation of term specificity and its application in retrieval // *Journal of Documentation*. 1972. V. 28. N 1. P. 11–21. <https://doi.org/10.1108/eb026526>
11. Rüschemdorf L. Wasserstein metric // *Encyclopedia of Mathematics* / ed. by M. Hazewinkel. Springer, 2000. P. 487–488.
12. Erdmann M., Glombitza J., Quast T. Precise simulation of electromagnetic calorimeter showers using a Wasserstein Generative Adversarial Network // *Computing and Software for Big Science*. 2019. V. 3. N 1. P. 4. <https://doi.org/10.1007/s41781-018-0019-7>
13. Goodfellow I., Pouget-Abadie J., Mirza M., Xu B., Warde-Farley D., Ozair S., Courville A.C., Bengio Y. Generative adversarial nets // *Advances in Neural Information Processing Systems 27: Annual Conference on Neural Information Processing Systems (NIPS)*. 2014. P. 2672–2680.
14. Farnia F., Ozdaglar A. Do GANs always have Nash equilibria? // *Proc. of the 37th International Conference on Machine Learning*, PMLR. 2020. V. 119. P. 3029–3039.
15. Тимофеев А.В. Метод выбора гиперпараметров в задачах машинного обучения для классификации стохастических объектов // *Научно-технический вестник информационных технологий, механики и оптики*. 2020. Т. 20. № 5. С. 667–676. <https://doi.org/10.17586/2226-1494-2020-20-5-667-676>

Автор

Тимофеев Андрей Владимирович — доктор технических наук, научный директор, ТОО «Эквалайзрум», Астана, 010000, Казахстан, [sc 56689367600](https://orcid.org/0000-0001-7212-5230), <https://orcid.org/0000-0001-7212-5230>, timofeev.andrey@gmail.com

References

1. Timofeev A.V., Groznov D.I. Classification of Seismoacoustic Emission Sources in Fiber Optic Systems for Monitoring Extended Objects. *Optoelectronics, Instrumentation and Data Processing*, 2020, vol. 56, no. 1, pp. 50–60. <https://doi.org/10.3103/S8756699020010070>
2. Choi K.N., Juarez J.C., Taylor H.F. Distributed fiber optic pressure/seismic sensor for low-cost monitoring of long perimeters. *Proceedings of SPIE*, 2003, vol. 5090, pp. 134–141. <https://doi.org/10.1117/12.484911>
3. Zuo J., Zhang Y., Xu H., Zhu X., Zhao Z., Wei X., Wang X. Pipeline Leak Detection Technology Based on Distributed Optical Fiber Acoustic Sensing System. *IEEE Access*, 2020, vol. 8, pp. 30789–30796. <https://doi.org/10.1109/access.2020.2973229>
4. Timofeev A.V., Maksimov P.N., Groznov D.I., Application of fiber optic technology for monitoring the mine water drainage pipeline system in the permafrost zone. *Gidrotehnika*, 2023, no. 3 (72), pp. 34–43. (in Russian). https://doi.org/10.55326/22278400_2023_3_34
5. Goodfellow I., Pouget-Abadie J., Mirza M., Xu B., Warde-Farley D., Ozair S., Courville A., Bengio Y. Generative Adversarial Nets. *Proc. of the 28th International Conference on Neural Information Processing Systems*, 2014, vol. 2, pp. 2672–2680.
6. Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., Bengio, Y. Generative adversarial networks. *arXiv*, 2014, arXiv:1406.2661. <https://doi.org/10.48550/arXiv.1406.2661>
7. Goodfellow Ian. NIPS 2016 Tutorial: Generative Adversarial Networks. *arXiv*, 2017, arXiv:1701.00160. <https://doi.org/10.48550/arXiv.1701.00160>
8. Goodfellow I., Bengio Y., Courville A. Back-Propagation and Other Differentiation Algorithms. *Deep Learning*, MIT Press, 2016, pp. 200–220.
9. Duchi J., Hazan E., Singer Y. Adaptive subgradient methods for online learning and stochastic optimization. *Journal of Machine Learning Research*, 2011, vol. 12, pp. 2121–2159.
10. Jones K.S. A Statistical interpretation of term specificity and its application in retrieval. *Journal of Documentation*, 1972, vol. 28, no. 1, pp. 11–21. <https://doi.org/10.1108/eb026526>
11. Rüschemdorf L. Wasserstein metric. *Encyclopedia of Mathematics*, ed. by M. Hazewinkel, Springer, 2000, pp. 487–488.
12. Erdmann M., Glombitza J., Quast T. Precise simulation of electromagnetic calorimeter showers using a Wasserstein Generative Adversarial Network. *Computing and Software for Big Science*, 2019, vol. 3, no. 1, pp. 4. <https://doi.org/10.1007/s41781-018-0019-7>
13. Goodfellow I., Pouget-Abadie J., Mirza M., Xu B., Warde-Farley D., Ozair S., Courville A.C., Bengio Y. Generative adversarial nets. *Advances in Neural Information Processing Systems 27: Annual Conference on Neural Information Processing Systems (NIPS)*, 2014, pp. 2672–2680.
14. Farnia F., Ozdaglar A. Do GANs always have Nash equilibria? *Proc. of the 37th International Conference on Machine Learning*, PMLR, 2020, vol. 119, pp. 3029–3039.
15. Timofeev A.V. Method for hyperparameter tuning in machine learning tasks for stochastic objects classification. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2020, vol. 20, no. 5, pp. 667–676. (in Russian). <https://doi.org/10.17586/2226-1494-2020-20-5-667-676>

Author

Andrey V. Timofeev — D.Sc., Chief Scientific Officer, Equalizum LLP, Astana, 010000, Kazakhstan, [sc 56689367600](https://orcid.org/0000-0001-7212-5230), <https://orcid.org/0000-0001-7212-5230>, timofeev.andrey@gmail.com