

УДК 53.088

УЛУЧШЕНИЕ МЕТРОЛОГИЧЕСКИХ ХАРАКТЕРИСТИК БЕЗЭХОВЫХ КАМЕР ЗА СЧЕТ АПОСТЕРИОРНОГО АНАЛИЗА НА ОСНОВЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ

Ю. С. ГОРШКОВА^{1), 2)}, С. В. МАЛЫЙ¹⁾, А. В. ТКАЧЕНЯ^{1), 2)}, И. Э. ХЕЙДОРОВ¹⁾

¹⁾Белорусский государственный университет, пр. Независимости, 4, 220030, г. Минск, Беларусь

²⁾ISsoft Solutions, ул. Чапаева, 5, 220034, г. Минск, Беларусь

Рассмотрена возможность улучшения метрологических характеристик безэховой камеры за счет апостериорной обработки результатов измерений на основе генеративно-состязательной модели искусственной нейронной сети в целях снижения влияния на распределение электромагнитного поля в измерительной зоне волн, отраженных от внешних границ камеры и расположенного в ней оборудования. Обучение нейронной сети осуществлено на

Образец цитирования:

Горшкова ЮС, Малый СВ, Ткачя А В, Хейдоров ИЭ. Улучшение метрологических характеристик безэховых камер за счет апостериорного анализа на основе искусственных нейронных сетей. *Журнал Белорусского государственного университета. Физика*. 2022;3:93–103. <https://doi.org/10.33581/2520-2243-2022-3-93-103>

For citation:

Harshkova YuS, Maly SV, Tkachenya AV, Kheidorov IE. Increasing the metrological characteristics of anechoic chambers due to a posteriori analysis based on artificial neural networks. *Journal of the Belarusian State University. Physics*. 2022;3:93–103. Russian. <https://doi.org/10.33581/2520-2243-2022-3-93-103>

Авторы:

Юлия Сергеевна Горшкова – аспирантка кафедры радиоп физики и цифровых медиатехнологий факультета радиоп физики и компьютерных технологий¹⁾, инженер-программист департамента интеллектуальных решений²⁾. Научный руководитель – С. В. Малый.

Сергей Владимирович Малый – кандидат физико-математических наук, доцент; заведующий научно-исследовательской лабораторией радиоп физики и информационных технологий кафедры радиоп физики и цифровых медиатехнологий факультета радиоп физики и компьютерных технологий.

Андрей Владимирович Ткачя – кандидат технических наук; доцент кафедры радиоп физики и цифровых медиатехнологий факультета радиоп физики и компьютерных технологий¹⁾, инженер-программист департамента интеллектуальных решений²⁾.

Игорь Эдуардович Хейдоров – кандидат физико-математических наук, доцент; заведующий кафедрой радиоп физики и цифровых медиатехнологий факультета радиоп физики и компьютерных технологий.

Authors:

Yuliya S. Harshkova, postgraduate student at the department of radiophysics and digital media technologies, faculty of radiophysics and computer technologies^a, and software engineer at the intelligent solutions department^b. jullietg@mail.ru

Sergey V. Maly, PhD (physics and mathematics), docent; head of the laboratory of radiophysics and information technologies, department of radiophysics and digital media technologies, faculty of radiophysics and computer technologies. maly@bsu.by

Andrei V. Tkachenya, PhD (engineering); associate professor at the department of radiophysics and digital media technologies, faculty of radiophysics and computer technologies^a, and software engineer at the intelligent solutions department^b. andreytkachenya@coherentsolutions.com

Igor E. Kheidorov, PhD (physics and mathematics), docent; head of the department of radiophysics and digital media technologies, faculty of radiophysics and computer technologies. igorhmm@mail.ru

наборе данных, которые были получены в рамках вычислительного эксперимента и включали в себя распределения электромагнитного поля в области безэховости для модели безэховой камеры и свободного пространства при заданных схемах размещения источников. Распределения действительной и мнимой частей электрической компоненты электромагнитного поля закодированы в виде цветных изображений. На примере двумерных моделей безэховых камер показана практическая реализуемость предложенного подхода к апостериорной обработке результатов измерений. Приведены методики оценки точности апостериорной обработки результатов измерений на основе метрик, используемых для оценки качества графических изображений, и вычисления погрешностей амплитуд электрической компоненты электромагнитного поля. Оценена возможность реализации предложенной методики апостериорного анализа в рамках натуральных микроволновых измерений в безэховых камерах.

Ключевые слова: безэховая камера; нейронные сети; генеративно-состязательные модели; распределение электромагнитного поля; метрологические характеристики.

INCREASING THE METROLOGICAL CHARACTERISTICS OF ANECHOIC CHAMBERS DUE TO A POSTERIORI ANALYSIS BASED ON ARTIFICIAL NEURAL NETWORKS

Yu. S. HARSHKOVA^{a, b}, S. V. MALY^a, A. V. TKACHENIA^{a, b}, I. E. KHEIDOROV^a

^aBelarusian State University, 4 Niezaliežnasci Avenue, Minsk 220030, Belarus

^bISsoft Solutions, 5 Čapajeva Street, Minsk 220034, Belarus

Corresponding author: Yu. S. Harshkova (jullietg@mail.ru)

This article considers the possibility of improving the metrological characteristics of an anechoic chamber due to a posteriori processing of measurement results based on a generative adversarial model of an artificial neural network in order to reduce the influence on the distribution of the electromagnetic field in the measuring zone of waves reflected from the outer boundaries of the chamber and the equipment located in it. The training of the neural network was carried out on a data set obtained as part of a computational experiment and including the distribution of the electromagnetic field in the anechoic region for the model of an anechoic chamber and free space for given source layouts. The distributions of the real and imaginary parts of the electric component of the electromagnetic field were encoded with colour images. On the example of two-dimensional models of anechoic chambers, the practical feasibility of the proposed approach to a posteriori processing of measurement results is shown. Methods for estimating the accuracy of a posteriori processing of measurement results based on the metrics used to assess the quality of graphic images and calculating the errors in the amplitudes of the electric component of the electromagnetic field are given. The possibility of implementing the proposed method of a posteriori analysis in the framework of natural microwave measurements in anechoic chambers is assessed.

Keywords: anechoic chamber; neural networks; generative adversarial models; electromagnetic field distribution; metrological characteristics.

Введение

Безэховые камеры (БЭК) являются важнейшим элементом метрологических комплексов микроволнового диапазона и широко используются для разработки антенных систем, решения задач радиолокации, электромагнитной совместимости, защиты информации, радиоэкологии, сертификации радиоэлектронного оборудования [1]. Они предназначены для создания условий измерения, близких к свободному пространству, а также обеспечения экранирования внутренних и внешних источников электромагнитного поля. Ключевыми факторами, влияющими на метрологические характеристики БЭК, являются форма, волновые размеры, уровень экранирования и качество радиопоглощающих покрытий (частотная, угловая и поляризационная зависимость коэффициента отражения). Основные способы улучшения характеристик БЭК – увеличение их размеров и применение высококачественных радиопоглощающих покрытий, что требует больших финансовых затрат и невозможно для уже построенных и используемых камер.

Технологии глубокого обучения искусственных нейронных сетей применяются для обработки результатов натуральных измерений в различных прикладных областях науки и техники [2].

Статья посвящена оценке потенциальных возможностей повышения точности измерений в БЭК за счет апостериорной обработки информации на основе предварительно обученных искусственных нейронных сетей.

Постановка задачи

Рассмотрим двумерную модель экранированной БЭК прямоугольной формы, эскиз которой представлен на рис. 1. Внутренняя поверхность камеры покрыта радиопоглощающим материалом. Внутри камеры выделены область, в которой может размещаться источник (см. рис. 1, 1), и область измерений (см. рис. 1, 2).




Рис. 1. Модель экранированной БЭК:

1 – область размещения источника; 2 – область измерений;
3 – источник электромагнитного поля; 4 – радиопоглощающее покрытие

Fig. 1. The model of the shielded anechoic camera:

1 – the source placement area; 2 – measuring area;
3 – source; 4 – radio-absorbing coating

Амплитудно-фазовое распределение электромагнитного поля в области измерений формируется за счет интерференции прямой электромагнитной волны, излучаемой источником, и волн, переотраженных от стенок БЭК. Интерес представляет разработка методик и алгоритмов, позволяющих на этапе апостериорной обработки информации минимизировать влияние отраженных от границ БЭК волн на распределение электромагнитного поля источника в области измерений.

Цель апостериорной обработки информации – преобразование результатов измерений для минимизации или устранения влияния переотраженных от границ БЭК электромагнитных волн. Для этого предлагается использовать технологии глубокого обучения искусственных нейронных сетей. Основными задачами реализации такого подхода являются:

- 1) выбор формата представления информации о распределении электромагнитного поля в области измерений;
- 2) выбор архитектуры нейронной сети;
- 3) формирование массивов данных для обучения и тестирования нейронной сети;
- 4) обучение сети;
- 5) адаптация технологии для проведения измерений в реальных БЭК.

Графическое описание распределения поля в области измерений и формирование данных для обучения и верификации нейронной сети на основе вычислительного эксперимента

Для двумерной модели БЭК в области измерений электрическая компонента поля описывается двумерным массивом комплексных чисел. Размеры массива определяются количеством дискретных отсчетов в пределах прямоугольной области. Элементы массива комплексных чисел могут быть представлены в двух форматах:

- действительные и мнимые части;
- амплитуды и фазы.

Первый формат является более предпочтительным, так как не содержит разрывов в распределении. Массивы действительных и мнимых значений электрической компоненты поля, в свою очередь, могут быть представлены в виде графических изображений. Выбор цветовой палитры позволяет аппроксимировать значения действительной и мнимой частей электрической компоненты поля в заданном динамическом диапазоне. Возможно и обратное однозначное преобразование. Графическое представление распределения полей обеспечивает визуальный контроль результатов апостериорной обработки.

Таким образом, при формировании набора данных для обучения и тестирования нейронных сетей должны быть сгенерированы пары изображений (одно изображение для БЭК, а другое – для свободного пространства или камеры с лучшими метрологическими характеристиками).

Для формирования указанного набора данных вместо проведения натурных измерений будем использовать две вычислительные модели БЭК, различающиеся типом радиопоглощающего покрытия. Модели основаны на методе конечных элементов и ориентированы на решение электродинамических задач в частотной области [3]. Геометрическая модель БЭК приведена на рис. 1. Камера имеет размеры 200×50 см. Ее внешние границы являются идеально проводящими. Стенки камеры покрыты плоским слоем радиопоглощающего материала толщиной 10 см со следующими параметрами: относительная диэлектрическая проницаемость – 1,0, относительная магнитная проницаемость – 1,0, удельная электрическая проводимость – $0,25$ См/м. Расчеты проводились на частоте 3 ГГц. Для плоского слоя радиопоглощающего покрытия с указанными выше параметрами, расположенного на плоском проводящем экране, при перпендикулярной поляризации плоской электромагнитной волны коэффициент отражения на частоте 3 ГГц варьируется от -12 до -5 дБ при изменении угла падения от 0 до 60° . Для реализации модели идеальной камеры в качестве поглощающего покрытия использовался идеально согласованный слой (PML-слой), обеспечивающий возможность решения внешних электродинамических задач в конечных пространственных областях. При проведении вычислительного эксперимента источники располагались в пространственной области, ограниченной прямоугольником размером 20×30 см, который размещался симметрично оси камеры на расстоянии 15 см от левой стенки. В качестве источников рассматривались электрические токи (одиночные, групповые, линейные), текущие вдоль линий, перпендикулярных плоскости двумерной модели БЭК. Электромагнитное поле рассчитывалось во всей камере. На рис. 2 показаны распределения действительной и мнимой частей электрической компоненты поля точечного источника для двух моделей БЭК, различающихся типом радиопоглощающего покрытия. Распределения действительной и мнимой частей в области измерений кодировались в виде цветных изображений.




Рис. 2. Распределение электрического поля точечного источника в БЭК:

- 1 и 2 – действительная и мнимая части электрического поля для идеальной камеры (с PML-слоями);
- 3 и 4 – действительная и мнимая части электрического поля для камеры с радиопоглощающим покрытием

Fig. 2. Electric field distribution of a point source in the anechoic chamber:

- 1 and 2 – real and imaginary parts of the electric field for a camera with perfectly matched layer;
- 3 and 4 – real and imaginary parts of the electric field for a camera with a radio-absorbing coating

Результаты моделирования показывают, что распределение электромагнитных полей в камерах с разным типом покрытий существенно отличается. Это обусловлено интерференцией основной волны и переотраженных от границ камеры волн. Перемещение источника в камере приводит к значительному изменению распределения электромагнитного поля в области измерений.

Для апостериорной обработки будем рассматривать распределение поля в области измерений, которая имела размеры 35×25 см и располагалась симметрично оси камеры на расстоянии 120 см от левой торцевой стенки. Данные для обучения и тестирования нейронных сетей включали в себя 1264 пары изображений, каждое из которых состояло из изображений действительной и мнимой частей электрического поля, полученных для моделей БЭК с двумя типами покрытий при одинаковых источниках и их пространственном размещении в камере.

Архитектуры нейронных сетей для апостериорной обработки результатов моделирования электромагнитных полей в БЭК

Поскольку объектами обработки являются изображения, то были выбраны два типа архитектур нейронных сетей, ориентированных на обработку изображений, – сверточный автоэнкодер [4] и генеративно-сопоставительная сеть Pix2Pix [5].

Автоэнкодеры – это нейронные сети прямого распространения, которые восстанавливают входной сигнал на выходе. Они вносят нелинейность в сеть с помощью функций активации, что позволяет на каждом из слоев выделять наиболее важные признаки и игнорировать шумы. Автоэнкодеры конструируются таким образом, чтобы не иметь возможности точно воспроизводить вход на выходе. Входной сигнал восстанавливается с ошибками из-за потерь при кодировании. Для того чтобы их минимизировать, сеть учится отбирать наиболее важные признаки. Автоэнкодеры состоят из двух частей – энкодера и декодера (рис. 3).




Рис. 3. Модель сверточного автоэнкодера:
1 – блок энкодера; 2 – блок декодера; 3 – вход нейронной сети;
4 – скрытый слой; 5 – выход нейронной сети

Fig. 3. The convolutional autoencoder model:
1 – encoder block; 2 – decoder block; 3 – neural network input;
4 – hidden layer; 5 – neural network output

Разработан сверточный автоэнкодер, имеющий следующую архитектуру: энкодер включает три блока, каждый из которых состоит из двух сверточных слоев и слоя субдискретизации; декодер также включает три блока, каждый из которых состоит из двух сверточных слоев и слоя апсемплинга. Автоэнкодер называется сверточным, поскольку в качестве операций кодирования и декодирования используются сверточные слои¹.

Рассмотрены архитектуры генеративно-сопоставительных нейронных сетей и их возможности для проведения апостериорной обработки результатов измерений. В общем случае генеративно-сопоставительные сети учатся транслировать случайный шум на входе в изображения на выходе. Условные генеративно-сопоставительные сети транслируют изображение на входе в некое выходное изображение. К такому типу и относится архитектура нейронной сети Pix2Pix, которая способна генерировать новые данные на основе входных признаков. Нейронная сеть Pix2Pix состоит из двух частей – генератора и дискриминатора. Архитектура генератора модели Pix2Pix представляет собой последовательную комбинацию из семи блоков энкодеров и семи блоков декодеров, следующих друг за другом. Общая архитектура модели Pix2Pix приведена на рис. 4.

Генератор модели Pix2Pix имеет тангенциальную функцию активации для более быстрого обучения. Дискриминатор представляет собой классификатор на основе сверточной сети, которая принимает на вход два изображения – реальное и сгенерированное. Задача дискриминатора – верно классифицировать изображения. Он состоит из шести сверточных слоев с сигмодой в качестве функции активации на выходе нейронной сети. Данная функция возвращает вероятность принадлежности к классу от 0 до 1 (значения, близкие к единице, указывают на то, что изображение реальное, а значения, близкие к нулю, соответствуют сгенерированному изображению).

¹Autoencoder: downsampling and upsampling [Electronic resource]. URL: <https://kharshit.github.io/blog/2019/02/15/autoencoder-downsampling-and-upsampling> (date of access: 09.11.2021).

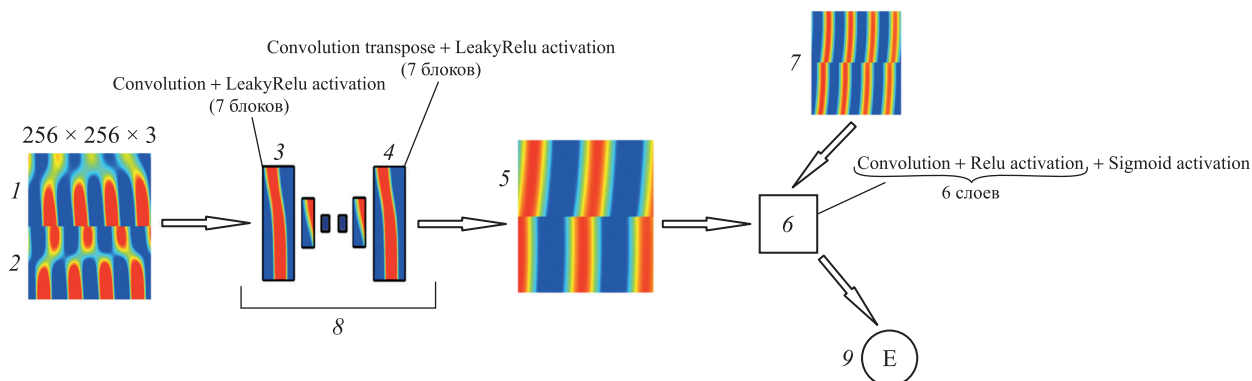


Рис. 4. Модель Pix2Pix: 1 – действительная часть поля; 2 – мнимая часть поля; 3 – энкодер; 4 – декодер; 5 – сгенерированное изображение; 6 – дискриминатор; 7 – реальное изображение; 8 – генератор; 9 – ошибка

Fig. 4. The Pix2Pix model: 1 – real part; 2 – imaginary part; 3 – encoder; 4 – decoder; 5 – generated image; 6 – discriminator; 7 – real image; 8 – generator; 9 – error

Ошибка нейронной сети в конце прямого прохода вычисляется по формуле бинарной кросс-энтропии² (при обучении дискриминатор старается минимизировать величину этой ошибки):

$$H_p = -\frac{1}{N} \sum_{i=1}^N (y_i \log(p(y_i)) + (1 - y_i) \log(1 - p(y_i))),$$

где y – бинарное значение метки экземпляра (1 – реальное изображение; 0 – сгенерированное изображение); $p(y_i)$ – вероятность того, что спрогнозированное изображение реальное; $1 - p(y_i)$ – вероятность того, что спрогнозированное изображение сгенерированное.

Ошибка обновляется таким образом, чтобы минимизировать потери, предсказываемые дискриминатором для сгенерированных изображений, помеченных как реальные. Генератор также обновляется, чтобы минимизировать среднюю абсолютную ошибку между сгенерированным и целевым изображениями, которая рассчитывается по следующей формуле:

$$\text{MAE} = \frac{\sum_{i=1}^n |y_i - x_i|}{n},$$

где y_i – предсказанное значение; x_i – реальное значение; n – количество всех экземпляров.

Таким образом, функция ошибки дискриминатора имеет вид

$$\text{Loss}(\text{generator}) = H_p + \lambda \cdot \text{MAE},$$

где λ – некоторое число, являющееся гиперпараметром модели (в рассматриваемой задаче $\lambda = 100$).

На вход нейронной сети подается RGB-изображение, а на выходе модель возвращает сгенерированное изображение.

В рассматриваемом случае изображение имеет размерность 256×256 пк и состоит из двух соединенных изображений размером 128×256 пк, где действительная часть амплитуды поля расположена сверху, а мнимая – снизу. Изображения были представлены в виде матрицы яркости пикселей, значения которой были приведены к диапазону от -1 до $+1$ для лучшей сходимости при обучении сети.

Сравнительный анализ эффективности нейронных сетей на задачах апостериорного анализа распределения электрического поля в БЭК

Указанные выше нейронные сети были обучены на основе данных, полученных в рамках вычислительного эксперимента. Для обучения автоэнкодера потребовалось 25 эпох. Нейронная сеть с архитектурой Pix2Pix обучалась при различных гиперпараметрах, представленных в таблице.

²Godoy D. Understanding binary cross-entropy / log loss: a visual explanation [Electronic resource]. URL: <https://towardsdatascience.com/understanding-binary-cross-entropy-log-loss-a-visual-explanation-a3ac6025181a> (date of access: 01.12.2021).

Гиперпараметры обучения
нейронной сети с архитектурой Pix2Pix
Learning hyperparameters
of neural network with Pix2Pix architecture

| | | | | |
|-----------------|-------|---------|---------|----------|
| Количество эпох | 50 | 100 | 200 | 1000 |
| Шаг обучения | 0,001 | 0,002 5 | 0,000 5 | 0,000 25 |

Обучение сети проводилось при разных типах функции активации генератора, а именно Relu и LeakyRelu. Функция Relu возвращает значения неотрицательных чисел, при этом зануляя все отрицательные значения, а функция LeakyRelu линейно приближает отрицательные числа к оси абсцисс снизу. Лучшие результаты были получены при количестве эпох, равном 100, и шаге обучения 0,002 5 с функцией активации генератора LeakyRelu.

На рис. 5 показаны результаты апостериорной обработки распределений электрической компоненты электромагнитного поля на основе сверточного автоэнкодера. Левый столбец изображений содержит варианты входных распределений поля в области измерений. Центральный столбец включает результаты обработки сетью. В правом столбце представлены целевые изображения, соответствующие БЭК с идеальным радиопоглощающим покрытием (PML-слоем). Визуальный анализ предсказанных изображений показывает, что сеть, реализованная на архитектуре автоэнкодера, не обеспечивает удовлетворительного преобразования исходного изображения, содержит шумы и размытость. Точность обработки ухудшается для сильно искаженных интерференционными эффектами входных изображений.

На рис. 6 показаны результаты апостериорной обработки распределений электрической компоненты электромагнитного поля на основе нейронной сети с архитектурой Pix2Pix.

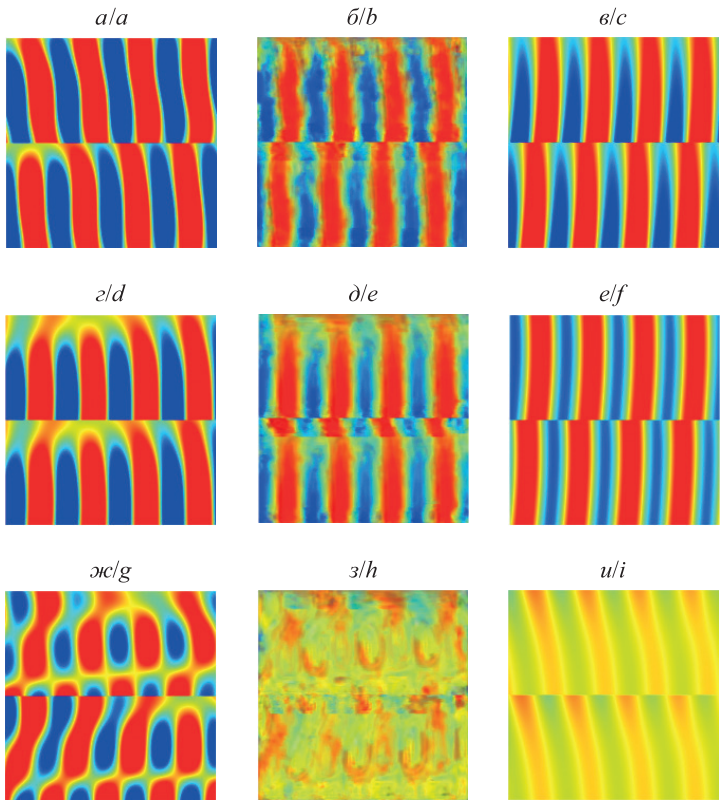


Рис. 5. Примеры апостериорной обработки на основе сверточного автоэнкодера:
а, г, ж – исходное изображение поля;
б, д, з – изображение, сгенерированное нейронной сетью;
в, е, и – целевое изображение для БЭК с идеальным покрытием
Fig. 5. Examples of a posteriori processing based on the convolution autoencoder:
а, d, g – original field image;
б, e, h – image generated by a neural network;
с, f, i – target image for an anechoic chamber with perfectly matched layer coverage

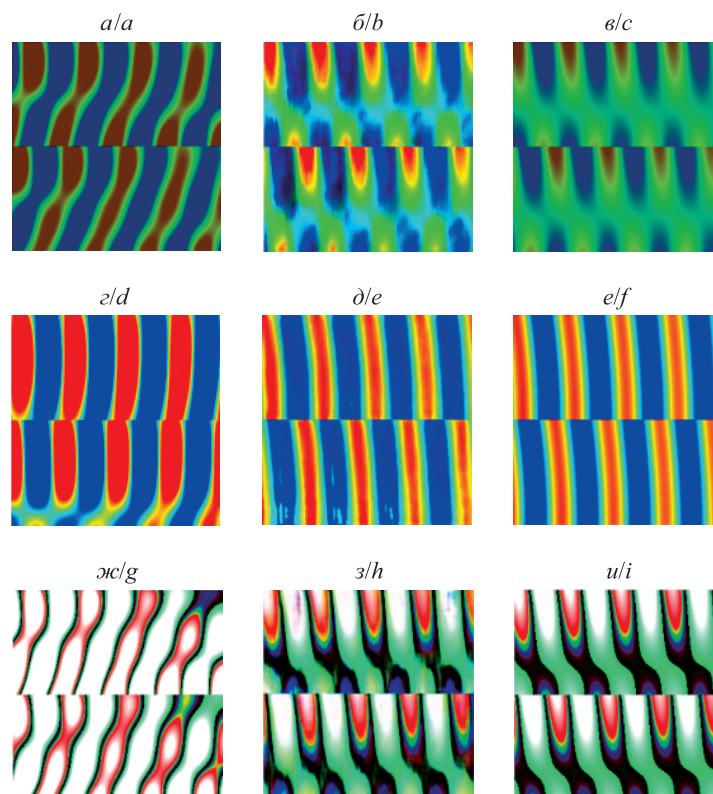


Рис. 6. Примеры апостериорной обработки на основе нейронной сети с архитектурой Pix2Pix:
а, з, ж – исходное изображение поля; б, д, з – изображение, сгенерированное нейронной сетью;
в, е, и – целевое изображение для БЭК с идеальным покрытием

Fig. 6. Examples of a posteriori processing based on a neural network with Pix2Pix architecture:
а, d, g – original field image; б, e, h – image generated by a neural network;
с, f, i – target image for an anechoic chamber with perfectly matched layer coverage

Сравнительная визуальная оценка входных, сгенерированных и целевых изображений распределения электромагнитных полей показывает, что нейронная сеть с архитектурой Pix2Pix успешно справилась с задачей апостериорной обработки результатов моделирования.

Оценка качества изображения является одним из основных этапов обработки изображений и имеет широкий спектр применения. Существующие методы оценки можно разделить на две категории:

- субъективную оценку качества – выполняется с участием людей, которые оценивают данные исходя из их опыта просмотра, и является наиболее точным и соответствующим человеческому восприятию методом оценки, однако при этом она затруднительна и неэффективна;
- объективную оценку качества – основывается на статистической информации об изображении.

Для оценки качества передачи, сжатия изображений либо видеосигналов на основе среднеквадратичной ошибки полученного или обработанного изображения по сравнению с исходным изображением обычно используется метрика PSNR [6]. Чем выше значение PSNR, тем меньше ошибка. Формула метрики качества PSNR имеет вид

$$\text{PSNR} = 20 \log_{10} \left(\frac{\text{MAX}_i}{\sqrt{\text{MSE}}} \right),$$

где MAX_i – максимальное значение, принимаемое пикселем изображения (когда пиксели имеют разрядность 8 бит, $\text{MAX}_i = 255$); MSE – среднеквадратичная ошибка.

Для измерения структурного сходства между двумя изображениями используется индекс SSIM. Он является методом прогнозирования воспринимаемого качества изображений и предполагает измерение либо прогноз качества изображения на основе исходного несжатого или свободного от искажений изображения, принятого в качестве эталона. Отличие от других методов, таких как MSE или PSNR, заключается в том, что эти подходы оценивают абсолютные ошибки. Структурная информация основывается на том, что пиксели имеют сильную взаимозависимость, особенно когда они пространственно близки. Эти зависимости несут важную информацию о структуре объектов визуальной сцены. Формула данной метрики записывается в следующем виде:

$$\text{SSIM}(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)},$$

где μ_x – среднее значение для первого изображения; μ_y – среднее значение для второго изображения; σ_x – среднее квадратичное отклонение для первого изображения; σ_y – среднее квадратичное отклонение для второго изображения; σ_{xy} – ковариация.

Результирующий индекс SSIM представляет собой десятичное значение от -1 до $+1$ (значение $+1$ доступно только в случае двух идентичных наборов данных и, следовательно, указывает на полное структурное сходство).

Рассмотрим метрику сравнения среднего значения ошибки между целевым и предсказанным изображениями для отображения областей с наибольшей и наименьшей ошибкой по всем данным. Для каждой области 8×8 пик исходного изображения рассчитывалась среднее квадратичная ошибка, полученный результат усреднялся. На рис. 7 показан пример использования этой метрики.

В ходе тестирования с помощью метрик оценки сходства изображений индекс SSIM вернул результат $0,627$ для модели Pix2Pix и результат $0,566$ для автоэнкодера. Это указывает на то, что изображения, сгенерированные нейронной сетью с архитектурой Pix2Pix, имеют схожую структуру. Значение $15,785$ получено метрикой PSNR для генеративно-состязательной модели, а значение $13,397$ – для автоэнкодера.

Приведенные выше методики оценки точности апостериорной обработки ориентированы на работу с изображениями. В реальных микроволновых измерениях интерес представляет оценка точности измерения напряженности электрической компоненты электромагнитного поля. Для получения этой оценки выполнено обратное преобразование от кодирования распределения поля в виде цветного изображения к массиву действительных чисел. Для фиксированного положения источника проведен сравнительный анализ результатов в области измерений для трех массивов данных, соответствующих распределению в камере с PML-слоями, распределению в камере с поглотителем и распределению, сгенерированному нейронной сетью.




Рис. 7. Распределение среднее квадратичной ошибки предсказания по областям изображения

Fig. 7. The distribution of MSE prediction by image regions

Относительные погрешности (в %) оценивались в каждой дискретной точке по формулам

$$\delta_{\text{predict}} = \frac{\left| |E_{\text{PML}}| - |E_{\text{predict}}| \right|}{|E_{\text{PML}}|} \cdot 100,$$

$$\delta_{\text{absorber}} = \frac{\left| |E_{\text{PML}}| - |E_{\text{absorber}}| \right|}{|E_{\text{PML}}|} \cdot 100,$$

где E_{PML} – электрическая компонента электромагнитного поля в идеальной БЭК; E_{absorber} – электрическая компонента электромагнитного поля в БЭК, стенки которой покрыты поглотителем; E_{predict} – электрическая компонента электромагнитного поля, предсказанная нейронной сетью.

Анализ результатов расчетов показал, что средняя величина относительной погрешности для случая камеры с неидеальным радиопоглощающим покрытием составила 41 %, после обработки результатов нейронной сетью средняя относительная ошибка равнялась 9 %. Эти оценки подтверждают работоспособность предложенной методики апостериорного анализа.

Реализация методики апостериорного анализа в условиях микроволновых измерений в БЭК

Рассмотрим возможность практического использования приведенной выше методики в условиях натурных измерений характеристик излучения антенн в дальней зоне. Для этого в качестве приемной измерительной системы применяется плоский сканер, обеспечивающий определение амплитудно-фазового распределения электромагнитного поля в дискретных точках пространства, расположенных в измерительной зоне. В роли тестовой антенны используется компактная слабонаправленная антенна, характеристики излучения которой известны (представлены в аналитическом виде, измерены в высококачественной БЭК, рассчитаны с использованием адекватных вычислительных моделей).

Для обучения нейронной сети формируется набор данных в виде значений электрической компоненты поля в фиксированном наборе точек, расположенных в области измерений. Процесс сбора данных может быть автоматизирован, включая перемещение эталонной антенны. На точность измерений оказывает влияние не только отражение от стенок БЭК, но и комплекс других факторов (отражения на стыках волноводных трактов измерительных систем, воздействие элементов сканера и т. д.). После обучения нейронной сети для определения значения электрической компоненты поля в заданной точке измерительной зоны проводится измерение электрического поля в наборе дискретных точек пространства с использованием сканера. Эти значения подаются на вход нейронной сети. Результатом апостериорной обработки является скорректированное распределение электрической компоненты поля в наборе дискретных точек, включая заданную.

Выводы

На основе вычислительного эксперимента по моделированию двумерных БЭК установлено, что предварительно обученные искусственные нейронные сети могут быть использованы для проведения апостериорной обработки распределения электромагнитного поля в БЭК в целях устранения или минимизации влияния волн, отраженных от границ камер.

Приведены архитектура и особенности обучения исследованных нейронных сетей, сравнительный анализ которых показал, что сеть с архитектурой Pix2Pix обеспечивает большую точность преобразования исходного распределения к тестовому.

На примерах продемонстрировано, что апостериорная обработка позволяет уменьшить среднюю относительную ошибку в величине амплитуды поля в области измерений с 41 до 9 %.

Рассмотрены особенности реализации предложенной методики апостериорного анализа в условиях натурального микроволнового эксперимента.

Библиографические ссылки

1. Мицмахер МЮ, Торгованов ВА. *Безэховые камеры СВЧ*. Москва: Радио и связь; 1982. 128 с.
2. Fausett L. *Fundamentals of neural networks: architectures, algorithms and applications*. [S. l.]: Pearson Education Inc.; 1993. XVI, 461 p.
3. Сагдеева ЮА, Копысов СП, Новиков АК. *Введение в метод конечных элементов*. Ижевск: Удмуртский университет; 2011. 44 с.

4. Zhang Yifei. A better autoencoder for image: convolutional autoencoder [Internet]. In: *ABCs 2018. 1st ANU bio-inspired computing conference; 2018 July 20; Canberra, Australia*. [S. l.]: [s. n.]; 2018 [cited 2021 November 9]. Available from: http://users.cecs.anu.edu.au/~Tom.Gedeon/conf/ABCs2018/paper/ABCs2018_paper_58.pdf.
5. Isola P, Zhu J-Y, Zhou T, Efros AA. Image-to-image translation with conditional adversarial networks. arXiv:1611.07004v3 [Preprint]. 2018 [cited 2021 November 9]: [17 p.]. Available from: <https://arxiv.org/abs/1611.07004v3>.
6. Fardo FA, Conforto VH, de Oliveira FC, Rodrigues PS. A formal evaluation of PSNR as quality measurement parameter for image segmentation algorithms. arXiv:1605.07116v1 [Preprint]. 2016 [cited 2021 December 1]: [11 p.]. Available from: <https://arxiv.org/abs/1605.07116v1>.

References

1. Mitsmakher MYu, Torgovanov VA. *Bezekhovye kamery SVCh* [Anechoic chambers UHF]. Moscow: Radio i svyaz'; 1982. 128 p. Russian.
2. Fausett L. *Fundamentals of neural networks: architectures, algorithms and applications*. [S. l.]: Pearson Education Inc.; 1993. XVI, 461 p.
3. Sagdeeva YuA, Kopysov SP, Novikov AK. *Vvedenie v metod konechnykh elementov* [Introduction to the finite element method]. Izhevsk: Udmurtskii universitet; 2011. 44 p. Russian.
4. Zhang Yifei. A better autoencoder for image: convolutional autoencoder [Internet]. In: *ABCs 2018. 1st ANU bio-inspired computing conference; 2018 July 20; Canberra, Australia*. [S. l.]: [s. n.]; 2018 [cited 2021 November 9]. Available from: http://users.cecs.anu.edu.au/~Tom.Gedeon/conf/ABCs2018/paper/ABCs2018_paper_58.pdf.
5. Isola P, Zhu J-Y, Zhou T, Efros AA. Image-to-image translation with conditional adversarial networks. arXiv:1611.07004v3 [Preprint]. 2018 [cited 2021 November 9]: [17 p.]. Available from: <https://arxiv.org/abs/1611.07004v3>.
6. Fardo FA, Conforto VH, de Oliveira FC, Rodrigues PS. A formal evaluation of PSNR as quality measurement parameter for image segmentation algorithms. arXiv:1605.07116v1 [Preprint]. 2016 [cited 2021 December 1]: [11 p.]. Available from: <https://arxiv.org/abs/1605.07116v1>.

Получена 11.04.2022 / исправлена 14.06.2022 / принята 18.06.2022.
Received 11.04.2022 / revised 14.06.2022 / accepted 18.06.2022.