

МЕТОД ЭКСТРАПОЛЯЦИИ СИГНАЛОВ НА ДВУМЕРНОЙ АНТЕННОЙ СИСТЕМЕ С ПРИМЕНЕНИЕМ АЛГОРИТМОВ ГЛУБОКИХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ РЕШЕНИЯ ЗАДАЧИ СВЕРХРАЗРЕШЕНИЯ¹

Рубинович Е. Я.²

(ФГБУН Институт проблем управления

им. В.А. Трапезникова РАН, Москва)

Юрченков И. А.,³ Назаркин В. А.⁴

(Российский технологический университет МИРЭА, Москва)

Рассматриваются методы дистанционного зондирования объектов с использованием цифровых антенных решеток (ЦАР). Такой подход позволяет получать информацию об объектах без прямого физического контакта, анализируя излучение, отраженное или испущенное ими. Описаны особенности формирования диаграммы приема (ДП) ЦАР, состоящей из двумерной плоской прямоугольной решетки излучающих элементов. Математическая модель ДН отдельного излучателя и системы в целом представлена с учетом волнового числа, расстояния между элементами и углов сканирования. Особое внимание уделено ограничениям разрешающей способности системы, обусловленным критерием Рэлея и связанным с линейными размерами антенны. В области малых угловых отклонений проводится аппроксимация компонент модели, что упрощает расчет, но ограничивает возможность различения близко взаимно расположенных источников в двумерном пространстве. Возникает задача цифровой обработки полученных сигналов для повышения углового разрешения системы. В статье обсуждаются методы и алгоритмы на базе глубоких нейронных сетей, направленные на преодоление этих ограничений и улучшение качества получаемых изображений при дистанционном зондировании с использованием ЦАР. В статье продемонстрированы качественные результаты работы предлагаемого решения на ЦАР с фиксированными параметрами. Визуально показаны примеры работы рассматриваемого алгоритма.

Ключевые слова: угловое сверхразрешение, сверточные нейронные сети, цифровая антенная решетка, критерий Рэлея, экстраполяция.

¹ Работа выполнена при финансовой поддержке РФФ, грант №23-29-00448.

² Евгений Яковлевич Рубинович, д.т.н., профессор (rubinych@gmail.com).

³ Иван Александрович Юрченков, аспирант (yurchenkov@mirea.ru).

⁴ Владимир Андреевич Назаркин, аспирант (vovannazark89@mail.ru).

1. Введение

Дистанционное зондирование — это метод получения информации об объектах или явлениях без прямого физического контакта с ними. Это достигается путем измерения и анализа излучения, отраженного или испущенного объектами, с помощью специализированных датчиков на борту спутников, самолетов, беспилотных летательных аппаратов и других платформ.

Измерение излучения может производиться в активном или пассивном режимах. При пассивном зондировании используются естественные источники излучения, такие как солнечный свет или тепло, излучаемое исследуемым объектом. Датчики регистрируют отраженное или испущенное излучение от поверхности объекта. При активном зондировании используются искусственные источники излучения, генерируемые самим датчиком (например, радаром или лидаром). Датчик излучает сигнал и измеряет время и интенсивность его отражения от поверхности.

У любой конфигурации системы излучателей при активном зондировании есть ограничение по разрешению — это минимальный угол, под которым она может различить два отдельных объекта и возможно возникновение эффекта слияния принятого сигнала от нескольких источников.

Эффект слияния целей возникает, когда два или более объекта находятся очень близко друг к другу по углу зрения антенны. Если расстояние между этими объектами меньше, чем разрешающая способность антенны, она не может различить их как отдельные объекты. Вместо этого она воспринимает их как один объединенный сигнал или единый объект.

Чтобы решить эту проблему и разделить слившиеся цели, применяется задача сверхразрешения. Это означает использование специальных методов и алгоритмов обработки сигналов, которые позволяют обойти физические ограничения разрешения антенны. Они анализируют полученные данные и извлекают из них дополнительную информацию, позволяя различить объекты, которые находятся ближе друг к другу, чем это позволяет обыч-

ное разрешение системы.

В задачах дистанционного зондирования принято группировать систему излучающих устройств в единую систему, образующую антенную решетку. Цифровая антенная решетка (ЦАР) представляет собой объединение элементов, работающих в активном режиме и расположенных в двумерном пространстве от своего центрального элемента на некоторых расстояниях друг от друга. Направление излучения ЦАР и в целом его угловое распределение описываются диаграммой приема (ДП) системы и регулируются изменением амплитудно-фазового распределения токов на излучающих элементах. ЦАР также снабжается набором цифровых вычислительных блоков общего или специального назначения, которые позволяют производить обработку принятого сигнала в реальном времени.

Во многих странах проводятся работы по исследованию и практической реализации методов обработки сигналов, позволяющих превысить физическое угловое разрешение ЦАР, т.е. достигать сверхразрешения [1, 3, 5, 7, 13, 22, 23, 25, 26]. Известны десятки подобных методов и их разновидностей. Тем не менее не существует единого универсального метода решения задачи достижения сверхразрешения. Все методы и алгоритмы имеют различные ограничения. Однако наиболее популярные из них [7, 13, 22, 25] оказываются эффективными только при решении задач для построения системы излучателей вдоль одного измерения. В двумерных задачах соответствующие алгоритмы значительно усложняются, что приводит к существенному увеличению времени обработки сигналов и иногда к необходимости использования параллельных вычислений [20]. Это не позволяет использовать упомянутые методы в режиме реального времени на вычислительных устройствах общего назначения. С развитием цифровых антенных решеток (ЦАР) появились новые методы улучшения углового разрешения. В современных работах рассматриваются модификации как программных, так и аппаратных улучшений.

С точки зрения программных модификаций в современ-

ных работах рассматриваются варианты методов MUSIC [11] и ESPRIT [24] на базе малоранговых аппроксимаций, которые позволяют оценивать направления на источники сигналов с разрешением, превышающим разрешение антенны, путем анализа собственных векторов и собственных значений ковариационной матрицы полученных сигналов. С точки зрения качественных изменений в этом направлении рассматриваются классические ЦАР с виде антенных решеток с частотным разнесением [9], включающие возрастающий и убывающий варианты изменения частоты излучения по элементам для улучшения диаграммы приема сигнала.

С недавнего времени ведутся перспективные исследования использования моделей искусственных нейронных сетей в задачах сверхразрешения как для увеличения детализации диаграммы приема одномерных [16] и двумерных [15] систем излучателей, так и для более точной оценки спектра принятых сигналов [27].

Работа посвящена разработке дополнительного алгоритмического модуля на базе алгоритмов искусственного интеллекта, позволяющего решить задачу сверхразрешения объектов в угломерном пространстве на базе известной конфигурации системы искусственных излучателей.

2. Постановка задачи

Двумерная плоская прямоугольная ЦАР выполняется в виде структуры из $(2N + 1) \times (2M + 1)$ равноотстоящих друг от друга элементов, каждый из которых характеризуется своей ДН $f_{n,m}(\alpha, \beta)$.

Диаграмма приема $f_{n,m}(\alpha, \beta)$ сигнала одного антенного устройства в рассматриваемой двумерной решетке моделируется в зависимости от значения волнового числа $k = 2 \cdot \pi / \lambda$, расстояния между устройствами по оси абсцисс d_α и ординат d_β , номера излучателя n по горизонтали и m по вертикали при сканировании угломерной области $\Omega \in \mathbb{R}[-1, 1] \times \mathbb{R}[-1, 1]$ следующим образом:

$$(1) \quad f_{n,m}(\alpha, \beta) = \exp(i \cdot k \cdot (d_\alpha \cdot n \cdot \alpha + d_\beta \cdot m \cdot \beta)),$$

где $n \in [-N, N]$; $m \in [-M, M]$; λ – используемая длина волны. Компоненты общей модели $\sin(\alpha)$, $\sin(\beta)$ приближаются своими значениями α, β ввиду необходимости решения задачи в малой области $\Omega(\alpha, \beta)$, $\alpha, \beta \ll 1$, в которой невозможно разрешать несколько близких источников сигнала. Рассматривать данную постановку диаграммы приема элемента можно как описание чисто пространственной (геометрической) фазовой задержки волны на элементах антенной решётки. Мы работаем в комплексной потенциальной форме представления волны, где временная часть $\exp(i\omega t)$ опущена для простоты и сфокусирован только пространственный множитель.

Тогда диаграмма приема системы $F(\alpha, \beta)$ описывается в виде двумерной суммы

$$(2) \quad F_{N,M}(\alpha, \beta) = \sum_{n=-N}^N \sum_{m=-M}^M f_{n,m}(\alpha, \beta).$$

Принятый сигнал на системе излучателей при известной модели диаграммы приема (2) естественным образом представляется в виде интегрального представления:

$$(3) \quad U(\alpha, \beta) = \iint_{\Omega(\alpha, \beta)} F(\varphi - \alpha, \psi - \beta) I(\varphi, \psi) d\varphi d\psi.$$

где $I(\varphi, \psi)$ – неизвестное угловое распределение амплитуды источников излучения в области Ω . Качество получаемого изображения на основе (3) определяется угловой разрешающей способностью, оцениваемой в соответствии с критерием Рэлея углами $\delta\alpha$ и $\delta\beta$:

$$(4) \quad \delta\alpha = \lambda/D_\alpha, \quad \delta\beta = \lambda/D_\beta,$$

где $D_\alpha = (2N + 1)d_\alpha$, $D_\beta = (2M + 1)d_\beta$ – линейные размеры антенны в соответствующих направлениях. Углы $\delta\alpha$ и $\delta\beta$ практически равны ширине диаграммы приема по половинной мощности $\theta_{0,5}$. Таким образом, описывающее объект распределение $I(\alpha, \beta)$ при прямых измерениях находится с разрешением не лучше $\delta\alpha$ и $\delta\beta$. Возникает задача цифровой обработки сигналов, которая позволила бы находить приближенные решения $I(\alpha, \beta)$ ин-

тегрального уравнения (ИУ) (3) и повысить тем самым качество двумерного изображения за счёт превышения критерия Рэлея (4).

Используя диаграмму приема элемента (1) и антенной системы (2), получим принимаемый сигнал в виде

$$(5) \quad U(\alpha, \beta) = \sum_{n=-N}^N \sum_{m=-M}^M C_{n,m} \exp(-ik(d_{\alpha}n\alpha + d_{\beta}m\beta)),$$

$$(6) \quad C_{n,m} = \iint_{\Omega(\alpha,\beta)} f_{n,m}(\varphi, \psi) I(\varphi, \psi) d\varphi d\psi, \\ n \in [-N, N], m \in [-M, M].$$

Ставится задача создания модели G с некоторыми внутренними параметрами $\mathbf{P}$, решающей задачу экстраполяции сигнала (7)

$$\hat{C}_{k,l} = G(C_{n,m} | \mathbf{P}),$$

и позволяющей получить с возможно большей точностью значения предсказываемого сигнала $\hat{C}_{k,l}$, $k \in [-K, K]$, $N < K$, $l \in [-L, L]$, $M < L$, который принимал бы элемент (k, l) за пределами физических размеров решетки (D_{α}, D_{β}) . Другими словами, ставится задача двумерной экстраполяции сигнала на основе известных реальных значений принятого сигнала на излучателях двумерной ЦАР, представленного в виде набора коэффициентов $C_{n,m}$.

На сегодняшний день задача экстраполяции или прогнозирования повсеместно решается с применением все более сложных и мощных алгоритмов на базе искусственных нейронных сетей различных архитектур.

Успешное решение задачи двумерной экстраполяции позволит найти виртуальный сигнал $\hat{U}(\alpha, \beta)$, принимаемый виртуальной ЦАР из $(2 \cdot K + 1) \times (2 \cdot L + 1)$ элементов вместо $U(\alpha, \beta)$ ЦАР из $(2 \cdot N + 1) \times (2 \cdot M + 1)$ элементов:

$$(8) \quad \hat{U}(\alpha, \beta) = \sum_{n=-K}^K \sum_{m=-L}^L \hat{C}_{n,m} \exp(-ik(d_{\alpha}n\alpha + d_{\beta}m\beta)).$$

Новое ядро ИУ (3) в виде диаграммы приема виртуальной ЦАР теперь представляет собой

$$(9) \quad \hat{F}_{K,L}(\alpha, \beta) = \sum_{n=-K}^K \sum_{m=-L}^L f_{n,m}(\alpha, \beta).$$

Возросшее число членов (6) позволит детализировать изображение источников излучения на получаемом двумерном сигнале $\hat{U}(\alpha, \beta)$. Угловая разрешающая способность системы, следуя критерию Рэлея (4), увеличится до теоретических значений

$$\delta\alpha = \lambda / ((2 \cdot K + 1) \cdot d_\alpha), \quad \delta\beta = \lambda / ((2 \cdot L + 1) d_\beta),$$

т.е. возрастет соответственно в $\sim K/N$ и $\sim L/M$ раз.

3. Нейронные сети для обработки изображений

Обработка изображений с целью увеличения их разрешения или масштабирования занимает важное место в компьютерном зрении. Для этого используются различные архитектуры нейронных сетей, способные обучаться восстанавливать недостающую информацию и улучшать визуальные характеристики изображений. На сегодняшний день для задач обработки изображений чаще всего рассматривается возможность использования моделей машинного обучения, предобученных на домене данных реалистичных изображений в трехканальном формате.

Super-Resolution Convolutional Neural Network (SRCNN) – одна из первых архитектур, предложенных для задач увеличения разрешения изображений [6]. Она состоит из небольшого числа сверточных слоев [19] и обучается восстанавливать изображение с большим числом пикселей в ширину и высоту из его версии с низким разрешением путем интерполяции и улучшения деталей.

Generative Adversarial Networks (GAN) – архитектуры [10], решающие задачу генерации изображений из семантического запроса [8]. В контексте увеличения размерности GAN, такие как SRGAN [14], обучаются генерировать высокореалистичные изображения, которые сложно отличить от оригинальных.

U-Net – изначально разработанная для сегментации медицинских изображений, архитектура [21] хорошо подходит для задач, где требуется точное восстановление или увеличение изображений.

Задача пространственной экстраполяции отличается от интерполяции тем, что требуется предсказать значения за пределами известных данных. При обработке изображений это означает генерацию новых областей за границами исходного изображения, что приводит к задачам дорисовывания границ. Это сложная задача, так как модель должна не только сохранять согласованность с имеющимися данными, но и уметь обобщать и предлагать правдоподобные продолжения структуры и текстуры.

В работе [4] рассматривается модель экстраполяции высокореалистичных изображений пространственных карт, использующая метод *Semantic Uncrop*, направленный на генерацию изображений, заполняющих произвольные двумерные формы. Модель при обучении использует одностороннее вырезание изображения из обучающего множества с целью его восстановления, в результате чего модель учится *дорисовывать* двумерную карту, используя оставшуюся в изображении доступную модели информацию. Этот подход выходит за рамки традиционных методов восстановления (*inpainting*) и расширения (*outpainting*) изображений, предоставляя возможность создавать содержательное и семантически согласованное изображение для областей произвольной формы. Предлагаемый подход основан на большой с точки зрения числа стадий обработки и обучаемых параметров модели, это влияет на скорость обучения, применения и возможность модификации процесса обработки входных данных.

Ограничения существующих моделей не позволяют рассматривать возможность их применения в представленной задаче экстраполяции двумерных карт $C_{n,m}$ входных данных. На это есть несколько объективных причин. Во первых, большинство доступных архитектур ориентированы на улучшение качества внутри границ изображения, т.е. на интерполяцию, а не на экстраполяцию. Во-вторых, универсальные модели не учитывают особенности конкретного типа сигнала или предметной области, поскольку учились на доменах изображений предметов реальных физических объектов при из достаточной разрешимости.

В данной работе рассматривается задача именно экстрапо-

ляции конкретных форм сигналов, что порождает необходимость создания собственной модели нейронной сети.

В основе представленных выше предобученных моделей нейронных сетей используются двумерные сверточные слои, основанные на применении операции дискретной свертки входных данных с ядром, параметры которых обучаются в процессе уменьшения функции потерь для решения задачи обучения с учителем.

Сверточные нейронные сети [19] являются основой для обработки изображений благодаря способности эффективно извлекать пространственные признаки. В задачах увеличения размерности сверточные слои обучаются моделировать связь между низкочастотными (общая структура) и высокочастотными (детали) компонентами изображения.

В стандартной двумерной сверточной операции мы применяем ядро (фильтр) к входной карте признаков для получения выходной карты признаков. Эта операция обычно уменьшает пространственные размеры, если шаг свертки больше единицы или если не предусмотрено заполнение изображения фиктивными пикселями.

Транспонированная свертка работает в обратном направлении, преобразовывая карту признаков низкого разрешения в карту более высокого разрешения (рис. 1), эффективно выполняя увеличение размерности, комбинированное с обучаемыми параметрами (весами сверточных ядер). Эту операцию можно рассматривать как расширение входной карты признаков по пространству на основе применения свертки к расширенной карте признаков.

Транспонированная свертка (*Transpose Convolution*) также часто называется деконволюцией (*deconvolution*) [28] (хотя технически это не истинная инверсия свертки) или сверткой с дробным шагом. Она особенно полезна в задачах, таких как генерация изображений и семантическая сегментация, где требуется преобразовать карты признаков низкого разрешения в изображения более высокого разрешения. Благодаря обучению весов сеть на ос-

нове транспонированной свертки может генерировать выходные данные высокого разрешения, которые более точны и согласованы с распределением обучающих данных.

$$\begin{array}{|c|c|c|} \hline X_{1,1} & X_{1,2} & X_{1,3} \\ \hline X_{2,1} & X_{2,2} & X_{2,3} \\ \hline X_{3,1} & X_{3,2} & X_{3,3} \\ \hline \end{array} * \begin{array}{|c|c|} \hline w_{1,1} & w_{1,2} \\ \hline w_{2,1} & w_{2,2} \\ \hline \end{array} =$$

$$\begin{array}{|c|c|c|c|} \hline X_{1,1} \cdot w_{1,1} & X_{1,1} \cdot w_{1,2} & 0 & 0 \\ \hline X_{1,1} \cdot w_{2,1} & X_{1,1} \cdot w_{2,2} & 0 & 0 \\ \hline 0 & 0 & 0 & 0 \\ \hline 0 & 0 & 0 & 0 \\ \hline \end{array} + \begin{array}{|c|c|c|c|} \hline 0 & X_{1,2} \cdot w_{1,1} & X_{1,2} \cdot w_{1,2} & 0 \\ \hline 0 & X_{1,2} \cdot w_{2,1} & X_{1,2} \cdot w_{2,2} & 0 \\ \hline 0 & 0 & 0 & 0 \\ \hline 0 & 0 & 0 & 0 \\ \hline \end{array} + \dots + \begin{array}{|c|c|c|c|} \hline 0 & 0 & 0 & 0 \\ \hline 0 & 0 & 0 & 0 \\ \hline 0 & 0 & X_{1,3} \cdot w_{1,1} & X_{1,3} \cdot w_{1,2} \\ \hline 0 & 0 & X_{1,3} \cdot w_{2,1} & X_{1,3} \cdot w_{2,2} \\ \hline \end{array}$$

Рис. 1. Действие транспонированной свертки по увеличению пространственного изображения

Разработка собственной архитектуры сверточной нейронной сети для экстраполяции сигнала на базе известного изображения с низким разрешением оправдана специфическими требованиями задачи. Собственная модель позволяет учитывать особенности данных и предметной области, улучшать качество экстраполяции, особенно в краевых областях за счет собственных решений в архитектуре и подразумевает возможность адаптировать архитектуру под конкретные цели и ограничения.

Таким образом, создание собственной модели для задач экстраполяции способствует получению более точных и правдоподобных предсказаний, что имеет важное значение в различных прикладных областях, где требуется прогнозирование данных за пределами доступной информации.

4. Решение задачи на основе сверточной модели нейронной сети

Для предложенной постановки задачи рассмотрим частный случай модели решётки с определёнными параметрами. При-

мом постоянными число излучателей существующей антенной решётки для $N = M = 10$ в каждую сторону от центрального излучателя, таким образом, всего в квадратной решётке будет $(2N + 1) \times (2M + 1)$ излучателей. Примем также расстояния между устройствами по горизонтали и вертикали в пространственной сетке постоянными и равными $d_\alpha = 0,7$ и $d_\beta = 0,7$ соответственно. Данные параметры напрямую влияют на пространственные размеры апертуры, равные также $D_\alpha = (2N + 1)d_\alpha = 14,7$ и $D_\beta = 14,7$.

Положим, что все излучатели работают на длинах волн, характеризующихся волновым числом $k = 2\pi$. Таким образом, для итоговой рассмотренной ЦАР мы имеем равную ширину диаграммы приема (4) до половинной мощности, оцениваемую величиной $\delta\alpha = \delta\beta = 2\pi/(kD_\alpha) \approx 0,068$ по каждому измерению. Данный параметр указывает на то, в пределах какого расстояния между объектами данные сигналы не могут быть разрешены по критерию Рэлея [29].

Предложенная модель двумерной антенной решетки при сканировании двумерной угломерной области предполагает генерацию некоторых значений принятого сигнала $C_{n,m}$ по соотношению (6) на каждом из устройств решетки, ввиду чего предполагается получение матрицы $C \in \mathbb{C}^{21 \times 21}$, в общем случае комплексных, значений $C_{n,m} \in \mathbb{C}$, каждое из которых участвует в расчете принятого сигнала (5). В итоге выходит, что имея фиксированную конфигурацию физических устройств ЦАР определяется только значениями матрицы C при определенной форме исходного истинного сигнала $I(\alpha, \beta)$. Будем решать задачу увеличения разрешающей способности ЦАР, т.е. уменьшению теоретических оценок значений $(\delta\alpha, \delta\beta)$ за счет прогнозирования значений принятого сигнала $\hat{C}_{k,l}$ на виртуальных излучателях за пределами реальной апертуры на основе принятой информации в $C_{n,m}$.

Введем виртуальную ЦАР с пространственными размерами $(2K + 1) \times (2L + 1)$ при $K = L = 60$, с теми же значениями расстояний между устройствами d_α, d_β , и волновым числом k . Таким образом принятый сигнал на ЦАР будет также определяться зна-

чениями сигнала, принятыми на устройствах $\hat{C}_{k,l}$, определенную в матрице комплексных значений размера $\hat{C} \in \mathbb{C}^{121 \times 121}$. Ставится задача обучения параметров $\mathbf{P}$ некоторой архитектуры нейронной сети G (7), увеличивающей пространственную размерность исходной матрицы C до матрицы $\hat{C}$, предсказывая принятые значения на виртуальных излучателях за пределами апертуры по модели (6).

Случайным образом будем генерировать наборы данных пространственных сигналов $I_j(\alpha, \beta)$, где $j = 1, 2, \dots, J$ и J – размер набора сигналов, представляющих обучающие примеры для предсказательного алгоритма G на примере трех равноинтенсивных объектов в двумерном угловом пространстве расположенных в точках $(\alpha_{ij}, \beta_{ij})$, $i = 1, 2, 3$, значения которых взяты из равномерного распределения симметрично относительно нуля в пределах ширины диаграммы приема до половинной мощности реальной апертуры. Значения амплитуды сигналов моделируются в виде дельта-функций $\delta(\alpha - \alpha_{ij}, \beta - \beta_{ij})$, представляющих максимальные мощности сигналов-источников, прошедших через амплитудный фильтр. Генерируемый сигнал $I_j(\alpha, \beta)$ примет вид

$$(10) \quad I_j(\alpha, \beta) = \sum_{i=1}^3 \delta(\alpha - \alpha_{ij}, \beta - \beta_{ij}).$$

Таким образом, двумерные карты как для реальных $C_{n,m}^j$ принятых сигналов на устройствах и виртуальных $\hat{C}_{k,l}^j$ будут сгенерированы для каждого варианта расположения объектов $I_j(\alpha, \beta)$ по выражению (6). Для реального сигнала $C_{n,m}^j$ будет также смоделирован случайный аддитивный шум, взятый из равномерного распределения, в диапазоне SNR от 20 (дБ) до 100 (дБ) (Signal-to-noise ratio) от $C_{n,m}^j$, и наложен на исходные реальные коэффициенты. Принимая данные условия получаем пары «вход – выход» для алгоритма G с обучаемыми параметрами $\mathbf{P}$ для пространственной экстраполяции.

На рис. 2 представлена разработанная архитектура модели нейронной сети на базе сверточных и транспонированных сверточных слоев, предназначенных для решения задачи экстраполяции

ная часть двумерной карты результата размерами (21×21) будет представлять незашумленный восстановленный сигнал на физически существующих устройствах исходной ЦАР, а остальные значения по краям будут целевыми предсказываемыми значениями.

Представленная архитектура (рис. 2) нейронной сети состоит из трёх последовательных функциональных блоков обработки получаемых пространственных данных.

Первый блок **ConvBlock2d** предназначен для извлечения первичных признаков и зависимостей входных двумерных карт. Он состоит из четырех последовательных сверточных слоев с размером ядра свертки $(CH \times 3 \times 3)$ и последовательно увеличивающимся количеством каналов глубины **CH** = (5, 10, 15, 20) и количеством таких ядер (фильтров) **DH** = (10, 15, 20, 40) на каждом слое. Каждый сверточный слой в данном блоке оснащен заполнением краев входного тензора данных одним фиктивным элементом по каждому направлению для сохранения исходных пространственных размеров по ширине и высоте (*padding*). Последовательное выполнение операции свертки производится без нелинейного преобразования и уменьшения размерности в виде слоев агрегации (*pooling*) для максимального сохранения размеров малой пространственной карты на входе. Итоговое поле восприятия (*receptive field*) сверточного блока составляет (9×9) значений по ширине и высоте. После данного блока выполняется нелинейное преобразование с помощью функции активации **SELU**(x) [29]:

$$(11) \quad SELU(x) = \zeta \cdot (\max(0, x) + \min(0, \gamma \cdot (\exp(x) - 1))),$$

где $\zeta \approx 1,0507$, а $\gamma \approx 1,6733$. Такая функция позволяет выделять пространственные коэффициенты результирующих карт свертки только с положительной корреляцией и пропускать далее полный не затухающий градиент для положительных входных значений. В качестве функции также может быть выбрана любая функция семейства **RELU**(x) [2].

Второй функциональный блок состоит из пяти последовательных транспонированных сверточных слоев увеличения раз-

мерности двумерной карты **ConvTranspose2d**. Данные сверточные слои в предлагаемой реализации снабжаются сверточными блоками в количестве равном $\mathbf{DH} = 40$ и размерами $(40 \times 21 \times 21)$, где первая константа $\mathbf{CH} = 40$ соответствует глубине двумерной карты, вторая $H = 21$ и третья $W = 21$ константы соответствуют размеру сверточных ядер по высоте и ширине соответственно. Данные блоки производят над входными тензорами размера $(40 \times H_{in} \times W_{in})$ преобразование увеличения двумерной карты до размеров $(40 \times H_{out} \times W_{out})$ посредством операции двумерной дискретной транспонированной свертки, где $H_{out} = H_{in} + 20$ и $W_{out} = W_{in} + 20$, т.е. высота и ширина выходной карты увеличиваются соответственно на 10 значений симметрично в каждую сторону от центра. Данные блоки каждый последовательно выполняют нелинейное преобразование с помощью функции активации (11) для обучения нелинейным зависимостям в данных.

Третий функциональный блок **ConvBlock2d** агрегирует информацию с последнего слоя увеличения пространственной размерности по глубине двумерных карт. Промежуточный тензор с размерами $(40 \times 121 \times 121)$, подаваемый на вход данного блока, необходимо преобразовать до целевых размеров $(2 \times 121 \times 121)$, где каждый канал представляет собой матрицу вещественных коэффициентов $(Re \hat{C}_{k,l}, Im \hat{C}_{k,l}) \in \mathbb{R}^{2 \times 121 \times 121}$ для действительной и мнимой составляющих комплексных (в общем случае) значений прогнозируемого принятого сигнала $\hat{C}_{k,l} \in \mathbb{C}^{121 \times 121}$ на виртуальных устройствах ЦАР. Данный блок работает схожим образом, что и первый, за исключением того, что глубина входных данных последовательно уменьшается с 40 до 2. Данный блок призван решить проблему артефактов, возникающих на границе решения, получаемого в результате последовательной транспонированной свертки для увеличения размерности.

Подробная информация о промежуточных размерностях данных двумерных карт в процессе прохождения информации через сверточную модель представлена в таблице 1.

Параметры данной модели располагаются в матрицах ядер двумерных классических и транспонированных сверточных бло-

ков и обучаются посредством уменьшения ошибок модели по увеличению размерности входных карт. Данные для входов и выходов в общем случае известны для известной исходной и целевой пространственной конфигурации ЦАР при известном расположении моделируемых целей из распределения интенсивностей $I(\alpha, \beta)$ и рассчитываются по формулам (1)–(6).

Таблица 1. Таблица размерностей данных и параметров сверточной нейронной сети

Слой	Кол-во DH	Размерность слоя (CH,H,W)	Данные (CH,H,W)
Input	–	–	(5,21,21)
Conv2d	10	(5,3,3)	(10,21,21)
Conv2d	15	(10,3,3)	(15,21,21)
Conv2d	20	(15,3,3)	(20,21,21)
Conv2d	40	(20,3,3)	(40,21,21)
ConvT2d	40	(40,21,21)	(40, 41, 41)
ConvT2d	40	(40,21,21)	(40, 61, 61)
ConvT2d	40	(40,21,21)	(40, 81, 81)
ConvT2d	40	(40,21,21)	(40, 101, 101)
ConvT2d	40	(40,21,21)	(40, 121, 121)
Conv2d	20	(40,3,3)	(20, 121,121)
Conv2d	15	(20,3,3)	(15,121,121)
Conv2d	10	(15,3,3)	(10,121,121)
Conv2d	2	(10,3,3)	(2,121,121)
Output	–	–	(2,121,121)

Продемонстрированная модель призвана решать задачу обработки тензоров данных, состоящих из нескольких матриц фиксированного размера, увеличивая их пространственный размер в несколько раз, используя алгоритмы экстраполяции данных по высоте и ширине. В результате прохождения информации через предложенную модель будем получать тензоры более высокой размерности, значения которых будут представлять прогнозные значения коэффициентов на виртуальных излучателях, которые могли бы быть получены в процессе активного зондирования области ЦАР с апертурой большего размера.

Для обучения модели будем генерировать обучающую выборку зашумленных сигналов C на реальной апертуре и моделируемых сигналов $\tilde{C}$ на большой апертуре, как множество пар входов-выходов для предложенной сверточной модели нейронной сети (рис. 2).

Для оценки ошибок экстраполяции двумерного сигнала будем использовать функцию потерь среднего квадрата ошибок $MSE(x, y)$ (*mean squared error*), оцениваемую по формуле

$$(12) \quad MSE(\tilde{C}, \hat{C}) = \frac{1}{4KL + 2(K + L) + 1} \cdot \sum_{k=-K}^K \sum_{l=-L}^L (\tilde{C}_{k,l} - \hat{C}_{k,l})^2.$$

Дополнительно оценим метрику **SSIM** (*structure similarity*, или структурная схожесть) [18], оценивающую степень визуального и структурного сходства информации для генерируемого и реального двумерного изображения в некоторых малых окнах. Метрика SSIM сравнивает окна изображений по яркости $l(x, y)$, контрастности $c(x, y)$ и структуре $s(x, y)$ в виде суммы:

$$(13) \quad SSIM(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)},$$

где x, y – генерация и реальное двумерное изображение; μ_x, μ_y – средние значения амплитуды окон из изображений x и y ; σ_x, σ_y – стандартные отклонения амплитуд в окнах; σ_{xy} – ковариация между окнами x и y ; $c_1 = 0,01 \cdot 255$, $c_2 = 0,03 \cdot 255$ – константы.

Итоговое значение SSIM рассчитывается по принципу скользящего окна некоторого размера по двум изображениям с одинаковой глубиной, в результате чего полученные значения схожести усредняются. В нашей задаче данную метрику мы будем применять для оценки схожести амплитуд сигналов двумерного предсказания $\hat{C}_{k,l}^j$ и моделируемого случая принятого сигнала на ЦАР с большим количеством устройств $\tilde{C}_{k,l}^j$.

Обучение параметров модели будем производить с помощью градиентного метода оптимизации *Adam* [12], минимизируя среднеквадратическую ошибку модели (12). Метод оптимизации Adam совершенствует классический метод стохастическо-

го градиентного спуска, вводя пересчет градиентов на основе экспоненциального скользящего среднего градиентов и квадратов градиентов, оценивая таким образом среднее значение импульса и вариабельности направления изменения параметров и находя локальный минимум за меньшее число шагов.

5. Результаты моделирования

Процесс обучения состоял в итеративной подаче на вход сверточной модели пакетов данных принятых сигналов $C_{n,m}^j$, $j = 1, \dots, b$, где $b = 50$ – количество данных в пакете, для различных случайных вариантов расположений объектов в малом угловом разрешении. Модели для решения задачи регрессии также предоставлялись смоделированные эталонные значения $\tilde{C}_{k,l}^j$ принятых сигналов на ЦАР с большим размером апертуры, соответствующих тем же расположениям моделируемых объектов. Каждую эпоху модели предоставлялся список сгенерированных двумерных карт входов и выходов, рассчитанных по модели (6) для 100 различных пакетов вариантов взаимного расположения объектов по (10). На каждой эпохе модель также только оценивала промежуточное качество на проверочной выборке, состоящей из 1000 случайно сгенерированных и не обновляемых каждую эпоху вариантов пар двумерных карт входов и выходов, полученных по тому же правилу. Модель обучалась на протяжении 50 эпох, минимизируя функцию (12). Итого размер выборки для обучения составляет $J = 50000$ различных уникальных вариантов взаимного расположения трех целей. Выбранная начальная скорость обучения модели – $lr = 5 \times 10^{-4}$. График динамики минимизируемой метрики качества в процессе обучения модели представлен на рис. 3.

На графике показаны итоговые графики динамики значений метрики (12) на обучающей MSE_{train} (штриховая линия) и проверочной выборке MSE_{val} (сплошная).

Финальные результаты по величинам метрик средней ошибки (12) составляют значения $MSE_{train} \approx 0,076$ на обучающей

выборке, и $MSE_{val} \approx 0,078$ на проверочной выборке. Ввиду полученных результатов можно судить о стабильном обучении модели и отсутствии переобучения, поскольку в динамике средних метрик по эпохам отсутствует визуально значимый рост значений MSE_{val} по сравнению с MSE_{train} . Также отметим достаточно большую разницу между значением метрики на первой и последней эпохе.




Рис. 3. График динамики качества работы модели

Архитектура модели и процесс обучения были реализованы с использованием фреймворка PyTorch языка программирования Python 3. Модель обучалась на персональном компьютере с шестиядерным процессором Intel core i5-10400f в связке с графическим ускрителем Nvidia RTX 3060Ti с 8Гб оперативной памяти под управлением WSL2 с операционной системой Ubuntu Server 22.04. Процесс обучения на графическом процессоре занял $2,5 \times 10^4$ с, или порядка 7 часов реального времени.

Качество работы модели было протестировано на отложенной выборке только входных сигналов с тремя объектами, расположенными внутри области, определяемой физическим ограничением разрешения исходной малой апертуры ЦАР.

Для визуальной оценки качества экстраполяции значений принятого зашумленного сигнала на реальной ЦАР обученной

моделью визуализируем несколько результатов экстраполяции на рис 4. Представленные графические представления по строкам сетки изображений показывают результаты экстраполяции для различных вариантов взаимного расположения целей в угломерном пространстве в пределах ширины диаграммы приема до половинной мощности реальной решётки.

На графиках сверху вниз показаны сравнительные результаты: во второй колонке экстраполяции сигналов по исходным значениям в первой колонке и в третьей колонке представлены идеальные значения, которых мы хотели бы в идеальном случае достичь по модели (6) для апертуры большего размера.

Графики представляют собой двумерную плоскую столбчатую диаграмму значений коэффициентов рассчитанной матрицы действительных значений сигнала на различных вариантах размеров апертуры. По оси абсцисс и ординат на всех графиках показаны порядковые номера устройств, расположенных в двумерной решетке друг относительно друга на расстояниях d_x, d_y , указанных ранее в постановке задачи. Цветом от белого до черного показаны возрастающие значения принятых сигналов на устройствах.

Первая строчка результата показывает рассчитанные значения коэффициентов для сигнала (10), представленного тремя объектами, расположенными на одной оси по вертикали ($\beta = 0$) с разными значениями расположениями объектов друг относительно друга с координатами по горизонтали, отстоящими друг от друга на величину в треть ширины диаграммы приема реальной решетки $(\alpha/(3\delta\alpha), 0), (0, 0), (-\alpha/(3\delta\alpha), 0)$. Заметим, что экстраполяция структурно совпадает с идеальной, но существуют мелкие искажения в особенности на границах. Для остальных представленных сравнений (строка 2, 3, 4) можно сделать схожий вывод.

Далее на основе полученных результатов построим графическую оценку качества решения задачи экстраполяции на основе графиков ошибок восстановления идеального сигнала на апертуре большего размера для сценария сближающихся целей.




Рис. 4. График пространственных данных интенсивности действительных значений коэффициентов принятого сигнала на приемных устройствах $C_{n,m}$ для реальной апертуры и зашумленных данных (первая колонка), $\hat{C}_{k,l}$ для экстраполяции за пределы апертуры (вторая колонка) и $\tilde{C}_{k,l}$ для модельных значений коэффициентов на большой апертуре (третья колонка)

Для оценки качества работы модели при сближающихся целях построим график (рис. (5)) с отображением метрик (12)–(13),

а также смежных метрик среднего отклонения по модулю (MAE) и гибридной функции ошибок *Huber* [17].

На рис. 5 показаны значения метрик при увеличивающихся расстояниях между объектами в двумерном пространстве в относительных угловых величинах в единицах диаграммы приема до половинной мощности реальной апертуры. С помощью вертикальной штрих-пунктирной линии отмечено теоретическое ограничение в виде ширины диаграммы приема апертуры с виртуальными источниками излучения. Линиями на графике указаны значения метрик ошибок экстраполяции сигналов по сравнению с теоретически возможным результатом большей апертуры по (6) с моделируемыми распределениями сигналов источников (10).




Рис. 5. Метрики качества в зависимости от расстояния между объектами

Сплошной тонкой линией зависимости указаны значения метрики MAE среднего отклонения значений коэффициентов по модулю, средней толщины линией указаны значения MSE (12), сплошной толстой линией показана зависимость гибридной метрики *Huber* по мере сближения целей, а также штриховой линией визуализированы значения обратной метрики $1 - SSIM$, которые изменяются в диапазоне от 0 до 1, где минимальное значение показывает на максимальную структурную схожесть экстраполя-

ции и идеальных значений, а максимальное – на полное различие результата и теоретической зависимости.

Покажем качество восстановления принятого сигнала $\hat{U}(\alpha, \beta)$ на основе которого в дальнейшем планируется принятие решения о положении объектов в угломерной развертке. Отобразим результат вычисления принятого сигнала по найденным в результате двумерной экстраполяции моделью G значений коэффициентов $\hat{C}_{k,l}$ на излучателях за пределами реальной апертуры.

Рассмотрим сценарий постепенно сближающихся целей с расстояния ширины диаграммы приема до половинной мощности реальной апертуры друг относительно друга и вплоть до расстояния в пределах теоретической ширины диаграммы приема виртуальной экстраполированной апертуры. На рис.6 показаны результаты вычисления принятого сигнала $\hat{U}(\alpha, \beta)$ в сценарии сближающихся целей.

На рис. 6 показано 4 варианта (сверху вниз) расположения объектов в двумерном угломерном пространстве. Мощность сигнала от всех источников моделируется одинаковой и большей, чем мощность шума.

Первая колонка графиков показывает линии уровня принятого сигнала $U(\alpha, \beta)$, рассчитанного для реальной апертуры ЦАР. Графики отображены по осям в величинах углов, выраженных в относительных единицах ширины ДН до половинной мощности реальной ЦАР. Белый цвет указывает на низкую интенсивность сигнала в точке пересечения углов развертки, в то время как затеняющиеся области указывают на увеличивающиеся амплитуды сигнала, вплоть до максимальной в виде черного цвета.

Вторая колонка графиков демонстрирует также линии уровня принятого сигнала $\hat{U}(\alpha, \beta)$, рассчитанного для предсказанных коэффициентов за пределами реальной апертуры в тех же обозначениях, что и в первой колонке, а третья колонка графиков показывает истинное расположение моделируемых точечных объектов в угломерном пространстве.




Рис. 6. График линий уровня функции двух переменных $U(\alpha, \beta)$ реальной апертуры (первая колонка) и $\hat{U}(\alpha, \beta)$ виртуальной апертуры (вторая колонка) при различных вариантах расположения объектов, генерирующих сигнал $I(\alpha, \beta)$ (третья колонка)

На визуализациях (рис. 6) можем отметить следующие особенности работы модели. Первая особенность заключается в хорошей локализации точечных целей в точках центров главных лепестков рассчитанного сигнала. Вторая особенность заключена в относительно близком моделировании теоретической ширины диаграммы приема виртуальной апертуры, меньшей, по графической оценке, как минимум в 4 раза, что видно в единицах исходной ширины ДН реальной апертуры. Третья особенность мо-

делирования сигнала по экстраполированным значениям заключается в хорошем разрешении сливающихся целей в точном соответствии с теоретическими оценками для функционирования системы с такой же конфигурацией и числом излучателей. Из графиков (рис. 6) также отметим, что виртуальная ЦАР разрешает объекты в меньшем угловом пространстве по сравнению с реальной ЦАР с достоверным расположением.

Отдельно рассмотрим ситуацию двух разрешимых скоплений объектов в случае, если имеется группа близких объектов и один удаленный в пределах ширины ДН исходной ЦАР. Данная модельная ситуация показана на рис. 6 в последней серии графиков. Отметим, что в данном случае расчет сигнала по коэффициентам показывает увеличенную интенсивность общего сигнала для группы сливающихся объектов и меньшую выделенную интенсивность принятого сигнала для удаленного объекта, что еще является разрешимым случаем.

Полученные результаты демонстрируют отличное качество разрешения объектов в пространстве, позволяя превысить исходных показатель пространственного углового разрешения реальной апертуры как минимум в 4 раза. Также показано, что не идеальные прогнозы при решении задачи экстраполяции с применением сверточной нейронной сети могут быть использованы при расчете принятого сигнала с большим успехом и вносить лишь минимальные искажения без потери качества разрешения объектов.

Предлагаемый метод решения задачи сверхразрешения объектов в двумерном угловом пространстве отличается от классических подходов в том, каким образом обрабатывается поступающий сигнал на систему детекторов, и может быть использован совместно с такими методами, как MUSIC [11] и ESPRIT [24] для уточнения углов направления прихода отраженного сигнала от объектов. Стоит отметить, что показанные результаты не являются конкурирующими с классическими алгоритмами, а представляют лишь дополнительные возможности для уточнения полученных результатов и модификации методов разрешения объ-

ектов для устройств с низкой разрешающей способностью.

Недостатком предлагаемого подхода является необходимость привязки алгоритма и его обучение на заранее выбранной архитектуре двумерной ЦАР с фиксированными параметрами излучателей и их взаимным расположением.

6. Заключение

В данной статье были исследованы методы дистанционного зондирования объектов с использованием цифровых антенных решёток и предложен подход, основанный на применении нейронных сетей для повышения углового разрешения системы. Представленная модель демонстрирует способность существенно улучшать пространственное разрешение ЦАР, превышая исходные показатели реальной апертуры как минимум в четыре раза. Это достигается посредством экстраполяции данных по высоте и ширине, что позволяет получать прогнозные значения коэффициентов на виртуальных излучателях, эквивалентных увеличенной апертуре.

Качество работы модели было подтверждено с помощью метрики структурной схожести, показывающей высокую степень визуального и структурного соответствия между сгенерированными и реальными изображениями. Полученные результаты демонстрируют, что даже при наличии неидеальных прогнозов применение сверточной нейронной сети позволяет минимизировать искажения без потери качества разрешения объектов.

Однако недостатком данного подхода является необходимость обучения модели на заранее выбранной архитектуре двумерной ЦАР с фиксированными параметрами количества излучателей и их взаимным расположением. В данной работе продемонстрирована возможность работы модели с количеством целей до трех включительно в пределах диаграммы приема двумерной системы до половинной мощности. Для большего числа целей работа построенной модели не тестировалась. В будущем планируется исследовать возможности адаптации алгоритма к различным конфигурациям ЦАР и условиям работы.

Таким образом, разработанный метод способствует преодолению ограничений, обусловленных физическими размерами антенны, и открывает новые перспективы в области дистанционного зондирования с использованием цифровых антенных решёток.

Литература

1. ABTAHI T. et al. *Accelerating convolutional neural network with FFT on embedded hardware* // IEEE Trans. on Very Large Scale Integration (VLSI) Systems. – 2018. – Vol. 26, No. 9. – P. 1737–1749.
2. AGARAP A.F. *Deep learning using rectified linear units (relu)* // ArXiv preprint. – 2018. – DOI: arXiv:1803.08375.
3. ALMEIDA M.S., FIGUEIREDO M.A. *Deconvolving Images with Unknown Boundaries Using The Alternating Direction Method Of Multipliers* // IEEE Trans. Image Process. – 2013. – Vol. 22, No. 8. – P. 3074–3086.
4. BOWEN R. S., CHANG H., HERRMANN C. et al. *OCONet: Image Extrapolation by Object Completion* // IEEE CVF Conf. on Computer Vision and Pattern Recognition (CVPR), Nashville, TN, USA, – 2021. – P. 2307–2317. – DOI: 10.1109/CVPR46437.2021.00234.
5. CANDLES E.J., FERNANDEZGRANDA C. *Super-Resolution from Noisy Data* // Journal of Fourier Analysis and Applications. – 2013. – Vol. 19, No. 6. – P. 1229–1254.
6. DA WANG Y., ARMSTRONG R., MOSTAGHIMI P. *Super resolution convolutional neural network models for enhancing resolution of rock micro-ct images* // ArXiv preprint. – 2019. – DOI: arXiv:1904.07470.
7. DUDIK M., PHILLIPS S.J., SCHAPIRE R.E. *Maximum Entropy Density Estimation with Generalized Regularization and an Application to Species Distribution Modeling* // Journal of Machine Learning Research. – 2007. – No. 8. – P. 1217–1260.

8. ELASRI M., ELHARROUSS O., AL-MA'ADEED S. et al. *Image Generation: A Review* // Neural Processing Letters. – 2022. – Vol. 54, No. 5. – DOI: 10.1007/s11063-022-10777-x.
9. FARTOOKZADEH M. *Frequency diverse arrays (FDAs) vs. phased arrays: On the application of FDAs for secure wireless communications* // ArXiv preprint. – 2020. – DOI: arXiv:2004.08585.
10. GOODFELLOW I. et al. *Generative adversarial nets* // Advances in Neural Information Processing Systems. – 2014. – Vol. 27.
11. HU YI-DING, DENG WEI-YAO, WU GU-XIN et al. *A wideband MUSIC algorithm using an improved empirical wavelet transform* // Measurement Science and Technology. – 2024. – Vol. 36, No. 1. – DOI: 10.1088/1361-6501/ad9516.
12. KINGMA D.P. *Adam: A method for stochastic optimization* // ArXiv preprint. – 2014. – DOI: arXiv:1412.6980.
13. LAGOVSKY B.A. *Superresolution by Extrapolation for Solving Remote Sensing Problems* // 25th Int. Crimean Conf. “Microwave and Telecommunication Technology”. Conference Proceedings. – 2015. – Vol. 2. – P. 1144–1146.
14. LEDIG C. et al. *Photo-realistic single image super-resolution using a generative adversarial network* // Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition. – 2017. – P. 4681–4690.
15. LIU WANLI. *Super resolution DOA estimation based on deep neural network* // Scientific Reports. – 2020. – Vol. 10, No. 1. – DOI: 10.1038/s41598-020-76608-y.
16. LU Y., GUAN H., YANG K. et al. *Improving the Accuracy of Direction of Arrival Estimation with Multiple Signal Inputs Using Deep Learning* // Sensors (Basel). – 2024. – Vol. 24, No. 10. – P. 2971–2982. – DOI: 10.3390/s24102971.
17. MALEKZADEH P. et al. *A Robust Quantile Huber Loss with Interpretable Parameter Adjustment in Distributional Reinforcement Learning* // ICASSP 2024-2024 IEEE Int. Conf. on Acoustics, Speech and Signal Processing (ICASSP). – IEEE,

2024. – P. 6120–6124.
18. NILSSON J., AKENINE-MILLER T. *Understanding ssim* // ArXiv preprint. – 2020. – DOI: arXiv:2006.13846.
 19. O'SHEA K. *An introduction to convolutional neural networks* // ArXiv preprint. – 2015. – DOI: arXiv:1511.08458.
 20. PRATT H. et al. *Fcnn: Fourier convolutional neural networks* // Machine Learning and Knowledge Discovery in Databases: European Conf. – ECML PKDD 2017, Skopje, Macedonia, September 18–22, 2017, Proceedings, Part I 17. – Springer International Publishing. – 2017. – P. 786–798.
 21. RONNEBERGER O., FISCHER P., BROX T. *U-net: Convolutional networks for biomedical image segmentation* // Medical image computing and computer-assisted intervention–MICCAI 2015: 18th Int. Conf. – Munich, Germany, October 5-9, 2015, proceedings, part III 18. – Springer International Publishing, –2015. – P. 234–241.
 22. SHCHUKIN A.A., PAVLOV A.E. *Parameterization of User Functions in Digital Signal Processing for Obtaining Angular Superresolution* // Russian Technological Journal. – 2022. – Vol. 10, No. 4. – P. 38–43.
 23. TAN W.Q., HOU Y.G. *Estimation Of Direction Of Source Arrival Based upon MUSIC and Capon* // Journal of Nanchang Institute of Technology. – 2008. – Vol. 27, No. 1. – P. 20-23.
 24. TANG ZH., ZHOU K., XU Y. et al. *An Estimation Method for Soft Fault Reflection Coefficient of Power Cable Based on Sliding-Window TLS-ESPRIT* // IEEE Trans. on Power Delivery. – 02.10.2024. – Vol. 39, No. 6. – P. 3092–3100. – DOI: 10.1109/TPWRD.2024.3452779.
 25. TIKHONOV A.N., ARSENIN V.YA. *Methods of solving ill-posed problems* // – Moscow.: Nauka, 1974
 26. UZUN I.S., AMIRA A., BOURIDANE A. *FPGA implementations of fast Fourier transforms for real-time signal and image processing* // IEEE Proc. on Vision, Image and Signal Processing. – 2005. – Vol. 152, No. 3. – P. 283–296.

27. WU LIU-LI, LIU ZHANG-MENG, HUANG ZHI-TAO. *Deep Convolution Network for Direction of Arrival Estimation With Sparse Prior* // IEEE Signal Processing Letters. – 2019. – Vol. 26, No. 11. – P. 1688–1692. – DOI: 10.1109/LSP.2019.2945115.
28. ZEILER M., KRISHNAN D., TAYLOR G. et al. *Deconvolutional networks* // Proc. of the IEEE Computer Society Conf. on Computer Vision and Pattern Recognition. – 05.08.2010. – P. 2528–2535. – DOI: 10.1109/CVPR.2010.5539957.
29. ZHOU S., JIANG L. *Modern description of Rayleigh's criterion*. // Physical Review A. – 2018. – Vol. 99. No. 1. – DOI: 10.1103/PhysRevA.99.013808.

METHOD OF SIGNAL EXTRAPOLATION ON TWO-DIMENSIONAL ANTENNA SYSTEM USING DEEP NEURAL NETWORK ALGORITHMS TO SOLVE THE SUPER-RESOLUTION PROBLEM

Evgeny Rubinovich, V.A. Trapeznikov Institute of Control Sciences of RAS, Moscow, Doctor of Science, professor (Moscow, Profsoyuznaya st., 65, rubinvch@gmail.com).

Ivan Yurchenkov, Russian Technological University, Moscow, graduate student (yurchenkov@mirea.ru).

Vladimir Nazarkin, Russian Technological University, Moscow, graduate student (vovannazark89@mail.ru).

Abstract: The article deals with methods of remote sensing of objects using digital antenna arrays (DAA). This approach allows obtaining information about objects without direct physical contact by analyzing the radiation reflected or emitted by them. The features of the formation of the directional pattern (DN) of a DAA consisting of a two-dimensional flat rectangular array of radiating elements are described. The mathematical model of the DN of an individual radiator and the system as a whole is presented taking into account the wave number, the distance between the elements and scanning angles. Special attention is paid to the limitations of the resolving power of the system due to the Rayleigh criterion and related to the linear dimensions of the antenna. In the region of small angular deviations the model components are approximated, which simplifies the calculation, but limits the possibility of distinguishing closely located sources. The problem arises of digital processing of the received signals to increase the angular resolution of the system. The article discusses methods and algorithms based on deep neural networks, aimed at overcoming these limitations and improving the quality of acquired images in remote sensing using DAA. The article demonstrates qualitative results of the proposed solution on the DAA with fixed parameters. Examples of the work of the considered algorithm are shown visually.

Keywords: angular super-resolution, convolutional neural networks, digital antenna array, Rayleigh criterion, extrapolation.

УДК 537.86

ББК 22.18

*Статья представлена к публикации
членом редакционной коллегии А.А. Галяевым.*

Поступила в редакцию 04.12.2024.

Дата опубликования 31.01.2025.