

## РЕШЕНИЕ ЗАДАЧИ СВЕРХРАЗРЕШЕНИЯ С ИСПОЛЬЗОВАНИЕМ МОДЕЛИ НЕЙРОННОЙ СЕТИ ПРЯМОГО РАСПРОСТРАНЕНИЯ<sup>1</sup>

Лаговский Б. А.<sup>2</sup>

*(Российский технологический университет МИРЭА, Москва)*

Рубинович Е. Я.<sup>3</sup>

*(ФГБУН Институт проблем управления  
им. В.А. Трапезникова РАН, Москва)*

Юрченков И. А.<sup>4</sup>

*(Российский технологический университет МИРЭА, Москва)*

*Рассмотрена и решена задача повышения эффективности управления подвижными объектами при использовании новых алгоритмов, улучшающих качество изображений, получаемых при обзоре пространства. Существенное повышение качества основано на достижении угловой разрешающей способности, в десятки раз превышающей критерий Рэля. Угловое сверхразрешение обеспечивает раздельное наблюдение нескольких объектов, не разрешаемых при прямом наблюдении, а сопутствующее повышение четкости изображений дает возможность фиксировать незаметные ранее детали образов сложных объектов. На этой основе возрастает вероятность правильных решений задач распознавания и идентификации. Для обеспечения углового сверхразрешения решена задача обучения полносвязной нейронной сети прямого распространения. Для многоэлементных приемо-передающих систем измерений предложен и обоснован экстраполяционный метод достижения углового сверхразрешения. Основу метода составляет экстраполяция значений комплексных амплитуд принятого сигнала отдельными элементами приемных устройств за пределы измерительной системы. Тем самым создается виртуальная система большего размера, для которой выполняется критерий Рэля, превосходящий по показателям критерий для физической системы. В итоге эффективное угловое разрешение возрастает пропорционально возрастанию размеров виртуальной системы. Исследованы и представлены сравнительные результаты математического моделирования работы нейросети и других методов экстраполяции.*

**Ключевые слова:** угловое сверхразрешение, критерий Рэля, экстраполяция, нейросети.

---

<sup>1</sup> Работа выполнена при финансовой поддержке РФФ, гранты №23-29-00448 и №23-19-00134.

<sup>2</sup> Борис Андреевич Лаговский, д.т.н., профессор (robertlag@yandex.ru).

<sup>3</sup> Евгений Яковлевич Рубинович, д.т.н., профессор (rubinvch@gmail.com).

<sup>4</sup> Иван Александрович Юрченков, аспирант (yurchenkov@mirea.ru).

## 1. Введение

Улучшение точности измерений и эффективной разрешающей способности угломерных систем за счет использования новых методов цифровой обработки сигналов позволяет повысить качество систем управления подвижными и стационарными объектами. В последнее время внимание исследователей привлекает возможность применения для этих целей нейронных сетей. Показано, что нейронные сети могут быть интегрированы в контур управления движением объектов, в том числе и автономных, для решения задач распознавания объектов, прогнозирования их поведения и оперативного реагирования на изменяющуюся обстановку.

Для многоэлементных приёмо-передающих систем измерений и наблюдений различной физической природы предложен и обоснован экстраполяционный метод достижения углового сверхразрешения. Основу метода составляет экстраполяция значений комплексных амплитуд принятого сигнала отдельными элементами приемных устройств за пределы измерительной системы. Тем самым создаётся виртуальная система большего размера. В итоге эффективное угловое разрешение возрастает пропорционально возрастанию размеров виртуальной системы.

Угловое разрешение в соответствии с критерием Рэля определяется как угол:

$$(1) \quad \delta\theta = \lambda/D,$$

где  $D$  — линейный размер антенны,  $\lambda$  — длина волны. Угол  $\delta\theta$  практически равен ширине диаграммы направленности (ДН) по половинной мощности  $\theta_{0,5}$ .

Во многих странах проводятся работы по исследованию и практической реализации методов обработки сигналов, позволяющих достигать сверхразрешения, т.е. превышения (1) [6, 14, 17–25]. Сверхразрешение, в частности, даёт возможность решать важные задачи выделения отдельных целей в составе групповых целей.

У всех упомянутых методов есть общий недостаток: требуется проведение большого объема вычислений и, как следствие,

невозможность их использования в режиме реального времени при быстро изменяющейся обстановке.

Представляемый метод достижения углового сверхразрешения позволяет оперативно реагировать на изменения обстановки, решать задачи идентификации и селекции появляющихся новых объектов, формировать на этой основе управляющие сигналы. Задачи такого рода особенно важны при наблюдениях за группами БПЛА, управления охотниками за БПЛА определённого типа, формирования оптимальных траекторий охотников в автоматическом режиме при быстро изменяющихся условиях, в том числе в автономном режиме.

В частности, управляющие сигналы в режиме реального времени вводят новую информацию об изменении положений отдельных объектов в групповых целях, о выявлении новых целей, о выделении объектов с заданными характеристиками, об исключении ранее выделенных объектов из списка выделенных, о прогнозных значениях траектории движения объектов наблюдения.

Таким образом, представляемые алгоритмы включаются в систему управления БПЛА, что заметно повышает ее эффективность

## **2. Постановка задачи**

Принятый цифровой антенной решеткой (ЦАР) сигнал  $U(\alpha)$  может быть представлен в виде интегрального преобразования:

$$(2) \quad U(\alpha) = \int_{\Omega} F(\alpha - \varphi) I(\varphi) d\varphi,$$

где  $\Omega$  – угловая область расположения источника сигнала;  $I(\alpha)$  – угловое распределение амплитуды отраженного (или излучаемого) им сигнала;  $F(\alpha)$  – ДН измерительной системы,  $\alpha$  – угол отклонения от центра направления сканирования ЦАР в пределах  $\Omega$ .

Ставится задача воспроизвести изображение источника сигналов  $I(\alpha)$  с угловым разрешением превосходящим значение, определяемое критерием Рэлея для данной конфигурации физи-

ческой системы. Принятый сигнал  $U(\alpha)$  и ДН ЦАР  $F(\alpha)$  считаются известными.

Таким образом, необходимо найти приближенное решение интегрального уравнения (ИУ) Фредгольма первого рода типа свертки (2) относительно неизвестной функции  $I(\alpha)$  с максимально достижимой точностью. Поставленная задача является обратной, она не удовлетворяет второму и третьему требованиям корректности по Адамару и оказывается неустойчивой [1].

Устойчивость решений может быть повышена при ином подходе, напрямую не сводящемся к решению ИУ.

Современные радио- и гидролокационные системы, основанные на использовании ЦАР, могут преобразовывать сигналы в цифровую форму уже на стадии приёма сигнала каждым элементом. Это позволяет проводить анализ и обработку гораздо большей информации, содержащейся в структуре принимаемого сигнала, чем обычные антенны. В частности, возможно достижение разрешающей способности, превышающей предел, определенный критерием Рэлея.

Пусть число элементов линейной ЦАР  $2N + 1$ , размеры одномерной области  $\Omega$  меньше ширины луча ЦАР  $\theta_{0,5}$ . Тогда ДН можно представить в виде

$$(3) \quad F(\varphi - \alpha) = \sum_{n=-N}^N \exp(-ikdn(\varphi - \alpha)),$$

где  $k = 2\pi/d$  – волновое число;  $d$  – расстояние между соседними излучателями;  $\alpha$  – направление максимума ДН. Для ЦАР (2) преобразуется в сумму:

$$(4) \quad \begin{aligned} U(\alpha) &= \sum_{n=-N}^N \exp(-ikdn\alpha) \int_{\Omega} \exp(ikdn\varphi) I(\varphi) d\varphi = \\ &= \sum_{n=-N}^N C_n \exp(-ikdn\alpha), \end{aligned}$$

$$(5) \quad C_n = \int_{\Omega} \exp(ikdn\varphi) I(\varphi) d\varphi$$

где коэффициенты  $C_n$  – комплексная амплитуда сигнала, принятого  $n$ -м элементом ЦАР.

Несложно показать, что в этом случае решение  $I(\alpha)$  выражается посредством коэффициентов  $C_n$ :

$$(6) \quad I(\alpha) = A \sum_{n=-N}^N \exp(-ikdn\alpha) C_n + \psi(\alpha),$$

где  $\psi(\alpha)$  — произвольная функция, ортогональная всем экспонентам из (6) на отрезке  $[-\lambda/d; \lambda/d]$ ;  $A$  — нормировочный коэффициент.

Из (5) следует, что различия в значениях  $C_n$  определяются только пространственным положением отдельных излучателей ЦАР. Следовательно, проанализировав расположение достаточно большого количества излучателей и значения соответствующего им набора коэффициентов  $C_n$ , можно с определенной точностью найти зависимость принимаемого сигнала от положения излучателя в решетке, и прогнозировать значения сигнала, который бы принимали излучатели за пределами истинной ЦАР. Далее, используя прогнозные значения  $C_m$  для  $m = \pm(N+1), \dots, \pm M$  вместе с измеренными ранее значениями, получим ДН виртуальной ЦАР (4) с  $2M+1$  излучателями. Ширина ДН при этом уменьшается в  $M/N$  раз. Во столько же раз увеличиваются точность угловых измерений и угловая разрешающая способность полученной виртуальной ЦАР.

В итоге полученное приближенное изображение объекта представляется в виде:

$$(7) \quad I(\alpha) \approx \sum_{n=-M}^M C_n \exp(-ikdn\alpha).$$

Таким образом, приближенное решение ИУ (2)–(4) сведено к определению значений возможно большего количества комплексных коэффициентов  $C_n$  за пределами ЦАР.

При поиске значений коэффициентов  $C_n$  для виртуальных элементов ЦАР (т.е. за пределами реальной ЦАР) необходимо использование методов прогнозирования.

Большинство статистических методов прогнозирования основаны на различных предположениях о типах зависимостей и связях между параметрами. Некоторые из подобных методов

прогнозирования с использованием статистической обработки сигналов требуют значительных вычислительных и временных ресурсов, что не позволяет использовать их в режиме реального времени.

Зависимость значений  $C_n$  (5) от расстояния до центра ЦАР вне зависимости от типа источника представляет собой плавную осциллирующую кривую. Известно, что подобные зависимости хорошо описываются с помощью метода линейного предсказания Берга с использованием рекурсивного алгоритма Левинсона [15]. В этом методе коэффициенты аппроксимации находятся при минимизации суммы двух функций квадратов невязок для «экстраполяции вперед» и «экстраполяции назад». Использование метода Берга позволяет заметно увеличить размеры виртуальной ЦАР по сравнению с исходной.

Известно однако, что наилучшие результаты при проведении экстраполяции, особенно сложных зависимостей, достигаются при использовании нейронных сетей [9]. Кроме того, важным преимуществом нейронных сетей является их способность к активному дообучению на новых подтвержденных примерах сигналов в процессе использования.

Нейронные сети могут быть интегрированы в контур управления движением объектов, в том числе и автономных, для оперативного реагирования на изменяющуюся обстановку.

Принцип прогнозирования зависимостей на основе алгоритмов искусственных нейронных сетей (ИНС) широко применяется в различных областях науки и техники в последние 20 лет. ИНС часто используются в прикладных задачах распознавания образов, обработки текстовой информации и аудиосигналов, в прикладных задачах робототехники и управления [2, 5, 7, 8, 10, 12, 13].

Для поставленной задачи возможно использование полносвязной ИНС прямого распространения, а также сверточной ИНС [3, 11]. Полносвязные ИНС прямого распространения применяются в задачах обработки одномерных зависимостей, ввиду простоты архитектуры нейронной сети, высокой скорости работы и эффективности использования вычислений. В рассматриваемом од-

номерном случае по скорости работы полносвязные и сверточные нейронные сети идентичны.

В представляемой работе было проведено сравнение качества экстраполяции методом Берга с классической реализацией полносвязной нейронной сети прямого распространения.

Полносвязная нейросетевая модель прямого распространения является функцией, представляемой в виде

$$(8) \quad \hat{y} = NN(x|W),$$

где  $W$  — вектор матриц параметров модели;  $x \in \mathbf{R}^f$  — входной вектор значений сигнала или прецедента, для которого нужно определить неизвестные в будущем целевые значения  $y$ ;  $\hat{y} \in \mathbf{R}^d$  — вектор оценки целевых значений  $y$ . Нейронная сеть отображает вектор входных данных  $x$  в выходной вектор оценки  $\hat{y}$  посредством серии линейных преобразований с нелинейными функциями активации.

Полносвязная нейросетевая модель состоит из соединенных в скрытые слои линейные нейроны с нелинейной функцией активации. По мере прямого распространения информации от входов к выходу к выходному вектору  $x$  применяется последовательная серия линейных преобразований с матрицами весов слоя и нелинейных преобразований на основе выбранных функций активации. Входные данные часто представляются в виде матрицы векторов  $X$ :

$$(9) \quad X = (x^{<1>}, x^{<2>}, \dots, x^{<s>}) \in \mathbf{R}^{s \times f}, \quad x^{<i>} \in \mathbf{R}^f,$$

$i \in 1, 2, \dots, s$ . Здесь  $s$  — количество примеров,  $f$  — размер вектора значений каждого примера. Значения на выходе нейронной сети представляются также в виде матрицы оценок  $Y \in \mathbf{R}^{s \times r}$ , где  $r$  — размер одного вектора меток, соответствующий своему входному вектору.

Каждый слой нейронной сети с  $L$  слоями обладает матрицей весов  $W^l, l \in 1, 2, \dots, L$ , взвешивающей выход из предыдущего слоя или входа на каждом нейроне текущего слоя. Все матрицы весов  $W = (W^1, W^2, \dots, W^L)$  нейронной сети обладают различными размерами, зависящими от размера  $f$  входных векторов, требуемого размера  $r$  выходных векторов и количества нейронов в каждом из слоев нейронной сети.

Веса  $W$  нейронной сети настраиваются в процессе обучения на тренировочной выборке примеров  $X_{train}$  и эталонных меток  $Y_{train}$  таким образом, чтобы минимизировать выбранный функционал ошибки  $\text{Loss}(Y, \hat{Y})$  на пространстве параметров нейронной сети. Вследствие чего ставится следующая задача оптимизации:

$$(10) \quad \text{Loss}(Y, NN(x|W)) \rightarrow \min_W .$$

Функционал ошибки между оценками  $\hat{Y}$  (8) и метками  $Y$  выбирается исходя из задачи и должен отражать качество решения задачи нейронной сетью в виде числовой метрики.

Существует множество функционалов качества для различных задач, решаемых алгоритмами искусственного интеллекта [4, 11]. Минимизация метрики качества (10) решения задачи (8) производится на основе алгоритма из семейства методов градиентного спуска с различными модификациями, в котором веса  $W$  итеративно обновляются на основе тестовых прогонов работы модели на тренировочной выборке  $X_{train}$  [11] и минимизации полученных ошибок между ответами модели (8) и метками  $Y_{train}$ . Качество итогового обучения принято проверять на тестовой отложенной выборке схожих примеров  $X_{test}$  в сравнении с эталонными метками  $Y_{test}$ .

Из недостатков выбранной архитектуры полносвязной нейронной сети можно выделить необходимость выбирать и привязываться к заранее обозначенным размерностям входных и выходных данных. В силу этого обстоятельства теряется гибкость в применении конкретной реализации нейронной сети с обученными параметрами на задаче с новыми требованиями к апертуре приемника и также ширине виртуальной системы, т.е. к горизонту прогноза для задачи экстраполяции.

Из достоинств применения ИНС можно отметить, что благодаря оптимизации матрично-векторных умножений на современных вычислительных устройствах ИНС в задачах одномерной обработки сигналов могут работать в режиме реального времени на центральных процессорах при использовании обученной ИНС. За счет простоты архитектуры и параллельной обработки данных

возможно быстрое обучение на новых данных при новых значениях апертуры  $D$  и  $\lambda$  по сравнению с остальными моделями и архитектурами ИНС. Данные аспекты позволяют рассматривать модели ИНС прямого распространения не только как мощный, но и быстрый метод экстраполяции данных.

### **3. Численные результаты. Сравнение методов экстраполяции**

Численные эксперименты по достижению сверхразрешения проводились на модели линейной ЦАР с числами элементов  $2K + 1$  и расстоянием  $d = 0,7\lambda$  между ними. Поставленная задача экстраполяции заключалась в получении значений принятого сигнала виртуальными излучателями по обе стороны от центрального на значение, во много раз превышающее размер реальной ЦАР.

На основе выборки с  $s = 40\,000$  наборов значений коэффициентов  $C_n$ ,  $n \in [-K, K]$ , принятого сигнала для моделируемой ЦАР и типовых распределений сигналов  $I(\alpha)$  коэффициентов была обучена модель полносвязной нейронной сети прямого распространения с тремя скрытыми слоями  $L = 3$  по  $P_l = 500$ ,  $l = 1, 2, 3$  нейронов в каждом. Выборка была сформирована на основе генерации  $I(\alpha)$  в виде случайных пар целей в пределах ширины ДН  $\theta_{0,5}$ .

Обучение модели полносвязной нейронной сети прямого распространения происходило на случайно сгенерированных выборках с применением метода оптимизации Adam [16] со стандартными гиперпараметрами  $\beta_1 = 0,9$  и  $\beta_2 = 0,999$ , начальной скоростью обучения  $l_r = 0,001$ .

Метод Adam был выбран как самый надежный по скорости и точности сходимости среди методов оптимизации [16]. Для оптимизации параметров модели применялся пакетный метод оптимизации с размером пакета наборов  $b = 400$ . В качестве минимизируемого функционала задачи (10) выступала среднеквадра-

тическая ошибка MSE:

$$(11) \quad \text{MSE}(Y, \hat{Y}) = \frac{1}{2b} \sum_{v=1}^b \|\hat{y}^{<v>} - y^{<v>}\|_2$$

где  $x^{<v>} \in X$  – вектор примера тренировочной или тестовой выборки;  $y^{<v>} \in Y$  – вектор меток;  $\hat{Y}$  – оценки меток нейронной сети на подвыборке  $X$ ;  $\|\cdot\|_2$  – евклидова норма вектора.

Обучение до плато на кривой обучения по метрике (11) заняло ориентировочно 2000 эпох, в каждой из которых нейронная сеть наблюдала заново случайно сгенерированную тренировочную выборку.

Для обученной модели нейронной сети были протестированы несколько сценариев использования. Первый сценарий – при симметричных источниках излучения, т.е. источники имели одинаковые амплитуды сигналов и располагались на угловых расстояниях  $t_1$  и  $-t_1$  и относительно нормали к ЦАР.

По заданным значениям коэффициентов  $C_n, n \in [-K, K]$ , реальной ЦАР проводилась экстраполяция значений принятого сигнала на виртуальные излучатели  $\hat{C}_m^{(NN)}$ ,  $m \in [-M, M]$ , с помощью модели ИНС.

Ошибка экстраполяции измерялась в виде среднеквадратической относительной ошибки:

$$(12) \quad \delta = \frac{\sum_{i=1}^N (\hat{y}_i - y_i)^2}{\sum_{i=1}^N y_i^2}$$

между оценкой значений  $\hat{C}_n$  по модели экстраполяции и идеальными значениями  $C_n$  при  $n \in [-M, M]$ ,  $M \gg K$ .

На рис. 1 и рис. 2 представлен результат работы модели при расположении целей от начала координат на угловом расстоянии  $\alpha_1 = -\alpha_2 = 0,1\theta_{0,5}$  что в 5 раз превышает разрешающую способность ЦАР.

На рис. 1 показаны экстраполированные значения  $\hat{C}_n$  на основе нейронной сети для положительной полуоси при  $n > K$ . Здесь сплошная жирная кривая – результат работы нейросетевой модели, штриховая линия – значения  $C_n$ , которые были бы у реальной ЦАР с таким же числом элементов. Качество экстраполяции следует признать хорошим.

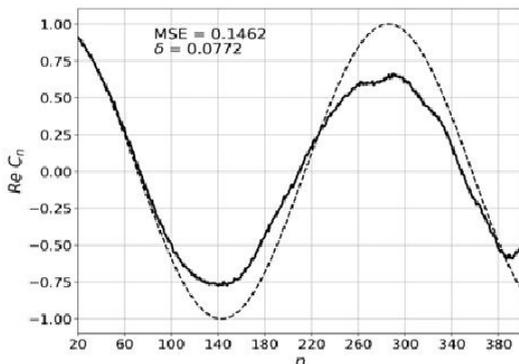


Рис. 1. Экстраполяция действительных частей  $C_n$

На графике также показаны метрики отклонения экстраполяции от теоретически идеальной зависимости  $C_n$  от положения приемного устройства  $n$ . Метрика  $MSE \approx 0,1462$ , а относительная ошибка  $\delta \approx 0,0772$ , что является вполне приемлемым результатом конкретно для решения задачи экстраполяции.

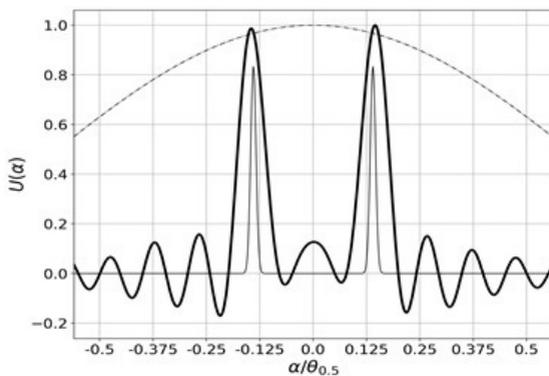


Рис. 2. Принятый сигнал при сканировании виртуальной системой

На рис. 2 изображен график распределения интенсивности источников излучения  $I(\alpha)$  (тонкая сплошная линия) и значения принятого ЦАР сигнала в угловом секторе  $\alpha/\theta_{0,5} \in \Omega$  в единицах ширины ДН. Сплошная жирная линия – результат работы ней-

росети, верхняя штриховая кривая – сигнал, принятый реальной ЦАР.

Две цели оказываются разрешены, критерий Рэлея превышен в три раза. Расположение каждого из объектов найдено с высокой точностью.

Сравним результат работы нейронной сети с алгоритмом экстраполяции Берга [15]. Алгоритм Берга является методом экстраполяции данных основанный на задаче авторегрессии.

На рис. 3 и рис. 4 показаны результаты решения задачи экстраполяции двумя методами.

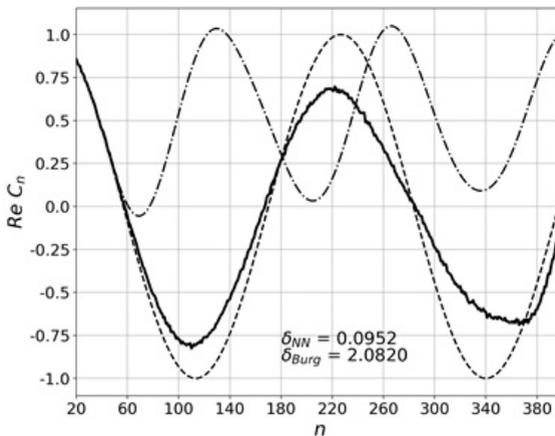


Рис. 3. Сравнение значений  $C_n$  для двух методов

На рис. 3 изображен график экстраполяции значений  $C_n$  принятого сигнала в зависимости от номера приемного устройства на основе нейронной сети для положительной полуоси при  $n > 20$  для двух близко расположенных целей. Сплошной жирной линией на графике показан результат нейросети; штриховой кривой – значения, которые были бы у реальной ЦАР с таким же числом элементов; штрихпунктирной линией отображены оценки  $\hat{C}_n^{(B)}$  по модели экстраполяции Берга.

На рис. 4 показана зависимость распределения интенсивности источников излучения  $I(\alpha)$  и значения принятого ЦАР сиг-

нала  $U(\alpha)$  в секторе  $\alpha \in \Omega$  в зависимости от угла сканирования  $\alpha/\theta_{0,5}$  в единицах ширины ДН. Оба алгоритма позволили разрешить два объекта. Нейросеть точно определила угловые положения каждого из объектов, амплитудные значения ложных источников оказались невелики, и ими можно пренебречь. Алгоритм Берга определил угловые положения объектов с заметной ошибкой. Кроме того, появилась ложная цель с амплитудным значением, вдвое превышающим амплитуды истинных целей.

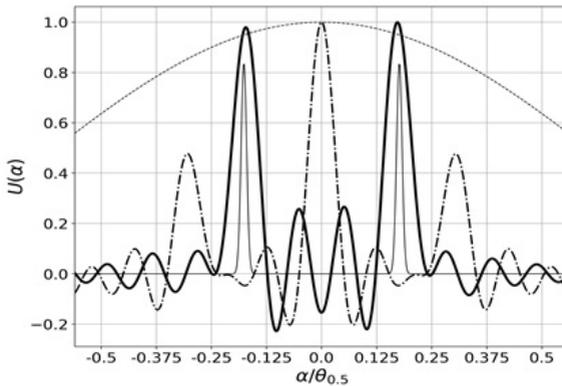


Рис. 4. Принятый при сканировании сигнал виртуальной системой при использовании экстраполяции Берга и нейронной сети

Рассмотрим теперь максимально достигаемый уровень сверхразрешения, обеспечиваемый рассматриваемыми методами экстраполяции. Для этого последовательно будем увеличивать число виртуальных приемных устройств  $n$ , и находить минимальное угловое расстояние между двумя одинаковыми объектами  $\theta_p$ , при котором они все еще будут различимы по критерию Рэлея.

На рис. 5 приведена зависимость необходимого углового разрешения виртуальной ЦАР  $\theta_p = \theta_{0,5}$  для отдельного наблюдения объектов от числа  $n$  виртуальных приёмных устройств. Сплошной линией показаны значения  $\theta_{0,5}$  виртуальной системы на ос-

нове экстраполяции нейронной сетью (NN), жирная штриховая кривая – значения  $\theta_{0,5}$  для виртуальной системы, значения  $\hat{C}_n$  которой получены на основе метода экстраполяции Берга.

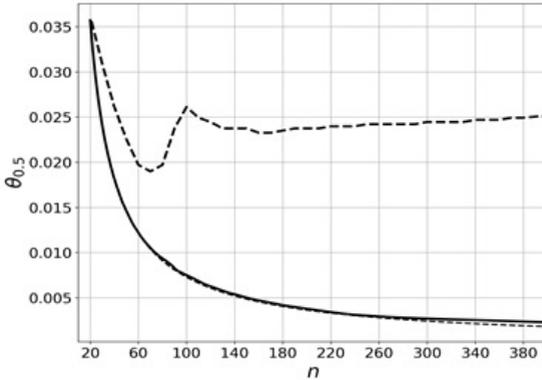


Рис. 5. Максимальная разрешающая способность в зависимости от числа виртуальных приемников

Представленные на рис. 5 результаты показывают, что добавление первых 30–50 виртуальных приёмников оказывает значительное влияние на повышение разрешения. Дальнейшее добавление приёмных устройств оказывается не столь эффективно. В сравнении с экстраполяцией нейронной сетью алгоритм Берга показывает значительно худшие результаты.

Численные эксперименты показали, что максимально возможное разрешение по Бергу превышает критерий Рэля в 2–3 раза. При предложенной нейросетевой экстраполяции максимально полученное разрешение превышает критерий Рэля в 10 раз.

Таким образом, результаты экстраполяции сигнала на основе нейронной сети по всем параметрам значительно превосходят результаты экстраполяции другими методами.

#### 4. Заключение

Обоснован и реализован на математической модели новый метод решения обратных задач по достижению углового сверхразрешения. Поставлена и решена задача применения полносвязной нейронной сети прямого распространения в задаче экстраполяции. Достижимая угловая разрешающая способность превышает критерий Рэлея в 3–10 раз. Изображения восстанавливаются с относительно небольшими ошибками в амплитудных значениях и в угловых положениях объектов.

Предложенные алгоритмы в сравнении с известными относительно просты, что позволяет использовать их роботизированными системами в режиме реального времени. Включение представленной нейронной сети в систему управления движением объекта, особенно автономного, значительно повысит эффективность и качество управления на основе оперативного решения задач определения положений и скоростей объектов, их распознавания, прогнозирования поведения в условиях быстро изменяющейся обстановки.

#### Литература

1. АРСЕНИН В.Я., ТИХОНОВ А.Н. *Методы решения некорректных задач*. – М.: Наука. –1974.
2. АХТЕРОВ А.В., КИРИЛЬЧЕНКО А.А. *Основы теоретической робототехники. Искусственные нейронные сети. (Обзор)* // Препринты Института прикладной математики им. М.В. Келдыша РАН. – 2008. – №10. – С. 2–20.
3. ВИНОГРАДОВА Е.П., ГОЛОВИН Е.Н. *Метрики качества алгоритмов машинного обучения в задачах классификации* // Научная сессия ГУАП. – 2017. – С. 202–206.
4. КАШИРИНА И.Л., ДЕМЧЕНКО М.В. *Исследование и сравнительный анализ методов оптимизации, используемых при обучении нейронных сетей* // Вестник ВГУ. Серия: Системный анализ и информационные технологии. – 2018. – № 4. – С. 123–132.

5. КОЗАР Б.А., КУГУРАКОВА В.В., САХИБГАРЕЕВА Г.Ф. *Структуризация сущностей естественного текста с использованием нейронных сетей для генерации трехмерных сцен* // Программные продукты и системы. – 2022. – Т. 35, №3. – С. 329–339.
6. ЛАГОВСКИЙ Б.А., РУБИНОВИЧ Е.Я. *Алгоритмы цифровой обработки данных измерений, обеспечивающие угловое сверхразрешение* // Мехатроника, автоматизация, управление. – 2021. – Т. 22, № 7. – С. 349–356.
7. МИНАЕВ Е.Ю., КУТИКОВА В.В., НИКОНОРОВ А.В. *Трекинг объектов в видеопотоке на основе сверточных нейронных сетей и фрактального анализа* // Сб. тр. IV международной конференции и молодежной школы «Информационные технологии и нанотехнологии» (ИТНТ-2018). – Самара: Новая техника. – 2018. – С. 2792–2798.
8. СЕМЕНЮК В.В., СКЛАДЧИКОВ М.В. *Разработка алгоритма распознавания эмоций человека с использованием сверточной нейронной сети на основе аудиоданных* // Информатика. – 2022. –Т. 19, №4.
9. СУКИНА С.А. *Нейронные сети* // Новая наука: стратегии и векторы развития. – 2016. – Т. 82, №5. – С. 248.
10. ТОРМОЗОВ В.С. *Настройка, обучение и тестирование нейронной сети долгой краткосрочной памяти для задачи распознавания образов* // Промышленные АСУ и контроллеры. – 2020. – № 3. – С. 52–57.
11. ШИШКИН Ю.Е., СКАТКОВ А.В. *Метрики качества для оценки и прогнозирования критических состояний* // Качество и жизнь. – 2019. – №1. – С. 61–66.
12. ЯМАШКИН А.А., ЯМАШКИН С.А. *Использование нейронных сетей прямого распространения для ландшафтного картографирования на базе космических снимков* // Геодезия и картография. – 2014. – №11. – С. 52–58.
13. ЯШИН В.И. *Растущие нейронные сети в робототехнике* // Роботизация Вооруженных Сил Российской Федерации. – 2020. – С. 279–284.

14. 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.
15. BURG J.P. *Maximum Entropy Spectral Analysis*. – PhD thesis, Department of Geophysics, Stanford University, Stanford, CA, 1975.
16. DIEDERIK P. KINGMA JIMMY BA. *Adam: A Method for Stochastic Optimization* // arXiv:1412.6980. – 2017.
17. KASTURIWALA S.B., LADHAKI S.A. *Superresolution: A novel application to image restoration* // International Journal on Computer Science and Engineering. – 2010. – No. 5. – P. 1659–1664.
18. LAVATE T.B., KOKATE V.K., SAPKAL A.M. *Performance Analysis of MUSIC and ESPRIT. DOA Estimation Algorithms for Adaptive Array Smart Antenna in Mobile Communication* // 2nd Int. Conf. on Computer and Network Technology (ICCNT), US. – 2010. – P. 308–311.
19. MORSE P., FESHBACH H. *Methods of Theoretical Physics*. – McGraw-Hill. Science/Engineering/Math, 1953. – 1978 P.
20. PARK S.C., PARK M.K., KANG M.G. *Super-resolution image reconstruction: a technical overview* // IEEE Signal Processing Magazine. – 2003. – Vol. 20, No. 3. – P. 21–36.
21. SHCHUKIN A.A., PAVLOV A.E. *Parameterization of user functions in digital signal processing for obtaining angular super-resolution* // Russian Technological Journal. – 2022. – Vol. 10, No. 4. – P. 38–43.
22. SROUBEK F., CRISTOBAL G., FLUSSER J. *Simultaneous Super-Resolution and Blind Deconvolution* // Journal of Physics: Conference Series. – 2008. – Vol. 124, No. 1. – P. 012–048.
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. UTTAM S., GOODMAN N.A. *Super-resolution of coherent sources in real-beam Data* // IEEE Trans. on Aerospace and Electronic Systems. – 2010. – Vol. 46, No. 3. – P. 1557– 1566.
25. WAWERU N.P., KONDITI D.B.O., LANGAT P.K. *Performance Analysis of MUSIC Root-MUSIC and ESPRIT* // DOA Estimation Algorithm. International Journal of Electrical Computer Energetic Electronic and Comm. Engineering. – 2014. – Vol. 8, No. 1. – P. 209–216.

## **SOLVING THE PROBLEM OF SUPER-RESOLUTION USING A MODEL OF A NEURAL NETWORK OF DIRECT PROPAGATION**

**Boris Lagovsky**, Russian Technological University, Moscow, Doctor of Science, professor (robertlag@yandex.ru).

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

**Ivan Yurchenkov**, Russian Technological University, Moscow, graduate student (qwerty29544@gmail.com).

*Abstract: The problem of increasing the efficiency of control of moving objects using new algorithms that improve the quality of images obtained during the survey of space is considered and solved. A significant improvement in quality is based on the achievement of angular resolution, tens of times higher than the Rayleigh criterion. Angular super-resolution provides separate observation of several objects that are not resolved by direct observation, and the accompanying increase in image clarity makes it possible to capture previously unnoticed details of images of complex objects. On this basis, the probability of correct solutions to recognition and identification problems increases. To provide angular super-resolution, the problem of creating a neural network has been solved. For multi-element receiving and transmitting measurement systems, an extrapolation method for achieving angular super-resolution is proposed and justified. The basis of the method is the extrapolation of the values of the complex amplitudes of the received signal by individual elements of the receiving devices outside the measuring system. Thus, a larger virtual system is created, for which its own Rayleigh criterion is fulfilled. As a result, the effective angular resolution increases in proportion to the increase in the size of the virtual system. Comparative results of mathematical modeling of the neural network and other extrapolation methods are investigated and presented, the limits of applicability of the method are determined.*

Keywords: angular super-resolution, Rayleigh criterion, extrapolation, neural networks.

УДК 537.86

ББК 22.18

DOI: 10.25728/ubs.2023.106.2

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

*Поступила в редакцию 03.11.2023.*

*Дата опубликования 30.11.2023.*