

ПРИМЕНЕНИЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ОЦЕНКИ НАПРАВЛЕНИЯ ПРИХОДА СИГНАЛА В ПОДВОДНОЙ СРЕДЕ

В.В. Бобров, Н.С. Смадыч, А.Ю. Родионов, Д.В. Зинченко

В статье рассматриваются подходы к решению задачи пространственной локализации источников звука в подводной среде как одного из фундаментальных вызовов современной гидроакустики. Анализируются ограничения классических алгоритмов оценки направления сигнала (Direction of Arrival - DoA) в системах пассивного мониторинга, подводной навигации и экологического контроля. Рассматриваются методы пеленгации с применением современных архитектур искусственных нейронных сетей. Приводится способ получения набора синтетических данных для глубокого обучения нейронных сетей различной архитектуры при помощи компьютерной симуляции гидроакустического канала связи в программе Bellhop. Представлены результаты моделирования линейного массива гидрофонов и выполнен анализ полученных данных. В заключение предложены подходы к повышению разрешающей способности и эффективности рассмотренного метода.

Ключевые слова: нейронные сети, искусственный интеллект, глубокое обучение, линейные антенные решетки, симуляция, гидроакустика

Введение

Задача пространственной локализации источников звука в подводной среде остается одной из основных проблем современной гидроакустики. Оценка направления прихода сигнала критически важна для систем пассивного мониторинга, подводной навигации мобильных объектов (водолазов, робототехнических комплексов). Однако, в отличие от распространения радиоволн в свободном пространстве, подводный акустический канал характеризуется сложной многолучевой интерференцией, дисперсией и пространственно-временной нестабильностью, обусловленной неоднородным профилем скорости звука.

Исторически развитие методов DoA шло по пути повышения спектрального разрешения. Ранние подходы, такие как метод формирования луча (Conventional Beamforming, CBF) или метод Бартлетта, опирались на технику «задержки и суммирования». Несмотря на их устойчивость к шумам, они ограничивались фундаментальным ограничением Рэлея, где разрешение лимитировалось физической апертурой антенной решетки. Для низкочастотных источников, типичных для подводной среды, это требовало создания массивов антенных элементов значительных размеров.

Прорывом 1970–80-х годов стало появление методов подпространств высокого разрешения, среди

которых доминирующее положение заняли алгоритм MUSIC (Multiple Signal Classification) [1] и его ротационная модификация ESPRIT [2]. Эти алгоритмы эксплуатируют ортогональность подпространств сигнала и шума, полученных из выборочной ковариационной матрицы. Теоретически MUSIC обеспечивает бесконечное разрешение при высоком отношении сигнал/шум (SNR) и достаточном количестве временных выборок. Однако в реальных условиях мелкого моря эффективность MUSIC резко падает. Основная причина кроется в физике среды: многолучевое распространение, вызванное отражениями от дна и поверхности, а также рефракция лучей. Это вызывает дефицит ранга ковариационной матрицы, разрушая математический фундамент подпространственных методов без применения техник пространственного сглаживания, которые, в свою очередь, уменьшают эффективную апертуру решетки.

В последнее десятилетие парадигма сместилась в сторону методов, управляемых данными (Data-Driven Approaches) [3, 4]. Нейронные сети, в частности сверточные (CNN) и рекуррентные (RNN) архитектуры, продемонстрировали способность аппроксимировать сложные нелинейные отображения между пространством сигналов и пространством углов, которые трудно формализовать аналитически. В отличие от

MUSIC, нейронные сети не требуют явного вычисления ковариационной матрицы в реальном времени. Более того, они способны запоминать структуру многолучевых помех, интерпретируя их не как шум, а как информативные признаки, характерные для конкретного волновода. Современные исследования всё чаще фокусируются на использовании глубокого обучения для работы в условиях сложного комбинированного шума и многолучевого распространения [5]. Тем не менее большинство существующих исследований в области глубокого обучения для определения направления прибытия сигнала (Deep Learning for DoA, Deep DoA) ограничиваются экспериментами на синтетических данных с аддитивным белым гауссовским шумом (AWGN), игнорируя сложную стохастическую природу реальных морских шумов. Существует критический разрыв между моделями, обученными на идеализированных симуляциях, и их производительностью в натуральных условиях.

В данной работе мы предлагаем гибридный подход, сочетающий физическое моделирование и глубокое обучение, исследуем применимость сверточной нейронной сети для оценки DoA источника тонального сигнала частотой 1 кГц, принимаемого 8-элементной эквидистантной линейной решеткой с межэлементным расстоянием $d = \lambda/2$. Ключевой особенностью метода является использование фазовой компоненты оконного преобразования Фурье (ОПФ) в качестве входных признаков, что позволяет нейронной сети извлекать временную динамику разности фаз, устойчивую к амплитудным флуктуациям. Обучение модели производится на синтетических данных, сгенерированных с помощью лучевой модели Bellhop, учитывающей реалистичные граничные условия и профиль скорости звука. Предположение об условиях узкой полосы пропускания требует, чтобы время прохождения сигнала через апертуру решетки было меньше времени когерентности генерируемого сигнала. Аналогично, накладывается условие дальней зоны и предполагается, что сигнал достигает решетки в виде плоской волны.

Рассмотрим в общей сложности N узкополосных сигналов $S_n(k)$, которые принимаются гидроакустической антенной решеткой, состоящей из M сенсорных элементов с межэлементным расстоянием d . Разность хода волн между элементами приемной решетки обозначается D_m и может быть выражена следующим образом:

$$D_m = (m-1)d \cdot \sin(\theta_n).$$

Фазовый сдвиг сигналов, приближающихся к антенной решетке, можно вычислить следующим образом:

$$\beta = e^{-j2\pi \frac{(m-1)d \cdot \sin(\theta_n)}{\lambda}}.$$

Следовательно, принимаемый элементом массива сигнал можно выразить суммой:

$$x_m(k) = \sum_{n=1}^N S_n(k) \cdot e^{-j2\pi \frac{(m-1)d \cdot \sin(\theta_n)}{\lambda}} + n_m(k).$$

В приведенном выше уравнении $n_m(k)$ представляет собой шумовую интерференцию на каждом элементе приемного массива сенсоров. Задача состоит в том, чтобы оценить направление прихода сигнала источника, основываясь на полученных данных от всех элементов массива.

■ Структура предлагаемого метода

На рис. 1 представлен графический обзор предложенного метода оценки направления прихода подводного гидроакустического сигнала на основе глубокого обучения с использованием классической сверточной нейронной сети (CNN) и временной сверточной нейронной сети (TCN). В общем виде предложенный метод можно разделить на несколько шагов. На первом шаге производится генерация синтетических данных в среде Bellhop для обучения нейронной сети, а на втором выполняется предобработка и выделение признаков сигнала, пригодных непосредственно для самого обучения.

■ Генерация синтетических данных в симуляторе Bellhop

Bellhop — это хорошо известная программная модель океанической среды. Она позволяет выполнять трассировку гидроакустических лучей и моделирование полей акустического давления в море с возможностью тонкой настройки параметров среды [6]. Поскольку Bellhop обеспечивает детальное моделирование подводного канала связи, его использование в данном исследовании для генерации подводных акустических сигналов полностью оправдано. Все необходимые характеристики канала связи, такие как количество многолучевых путей, углы падения, потери при распространении, амплитуды и задержки рассчитываются путём задания параметров геометрии канала, профиля скорости звука, подводной топографии и потерь при отражении от границы раздела сред. В таблице представлены параметры симуляции, использованные в данной работе.

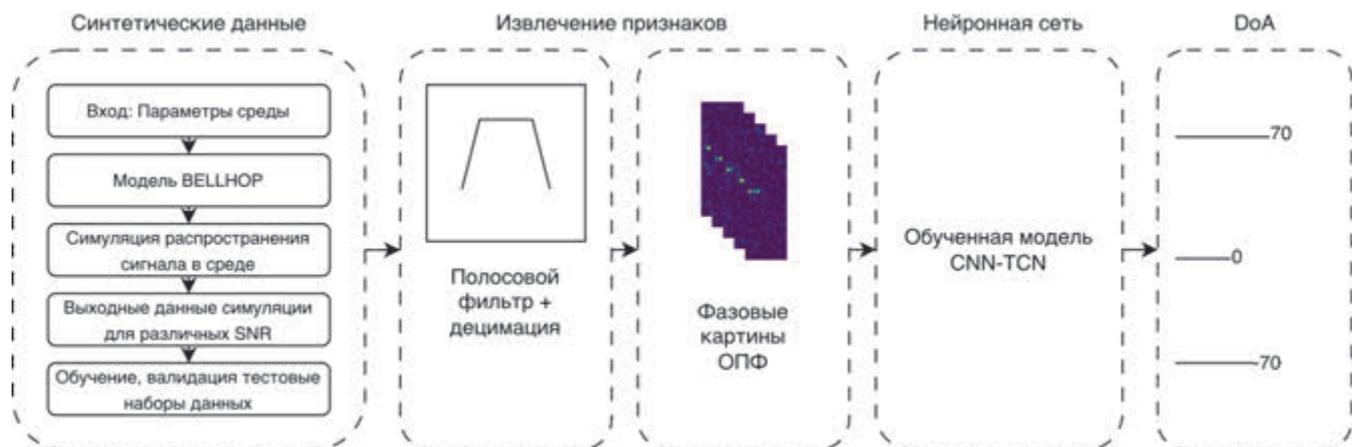


Рис. 1. Структура предложенного метода

Выбор симулятора Bellhop в качестве основного инструмента моделирования обусловлен его способностью с высокой точностью воспроизводить многолучевую структуру гидроакустического канала, что является критическим фактором для обучения нейронных сетей, предназначенных для оценки угловых координат источника. В основе Bellhop лежит метод гауссовых пучков, который, в отличие от классической лучевой теории, корректно обрабатывает зоны каустик и зоны тени, обеспечивая физически адекватное распределение амплитуд и фаз сигналов. Для задач машинного обучения ключевым преимуществом симулятора является возможность прямого извлечения временных задержек для каждого луча. Это позволяет формировать размеченные наборы данных с высокой степенью детализации. Кроме того, высокая вычислительная скорость Bellhop позволяет генерировать репрезентативные обучающие выборки объемом в десятки тысяч сценариев, охватывающих различные профили скорости звука и типы донного грунта, что необходимо для обеспечения обобщающей способности нейросетевых алгоритмов пеленгования в условиях априорной неопределенности морской среды.

Параметры среды распространения Bellhop

Параметр	Значение
Частота источника, Гц	1000
Глубина источника, м	20-80
Удаленность источника, м	500-3000
Глубина приемника, м	75
Средняя глубина акватории, м	100
Скорость звука, м/с	1500
Плотность, г/см ³	1,03
Диапазон трассировки, град	-70 ... 70

■ Признаки сигнала для обучения нейронной сети

Извлечение признаков направлено на получение представления, которое позволит нейронной сети оценивать значения угловых координат с помощью глубокого обучения. В этой статье используется развернутая и нормализованная фазовая составляющая оконного преобразования Фурье (ОПФ), представленная на рис. 2 и 3 при SNR 20 и 40 дБ соответственно.

Перед вычислением ОПФ принятые сигналы проходят полосовую фильтрацию с целью выделения частотного диапазона, содержащего надёжную пространственную информацию, после чего выполняется децимация. Далее к обработанным данным применяется ОПФ, в результате которого функция фазы приобретает разрывы первого рода. Последующая процедура разворачивания фазы (Phase Unwrapping) применяется для преобразования циклических фазовых признаков в линейно-зависимые от геометрических параметров антенной решетки. Это исключает появление ложных высокочастотных компонент во входных данных, вызванных математическими разрывами функции, и обеспечивает стабильную сходимость весов нейросетевых моделей. Далее производится нормализация полученных значений и масштабирование разностей фаз (например, в диапазон [-1, 1]), чтобы облегчить сходимость алгоритмов градиентного спуска при обучении модели. Такая предобработка позволяет снизить уровень шума, повысить согласованность фазовых признаков и уменьшить размерность пространства признаков.

Вычисление ОПФ для сигналов, полученных с элементов массива, выполняется следующим образом:

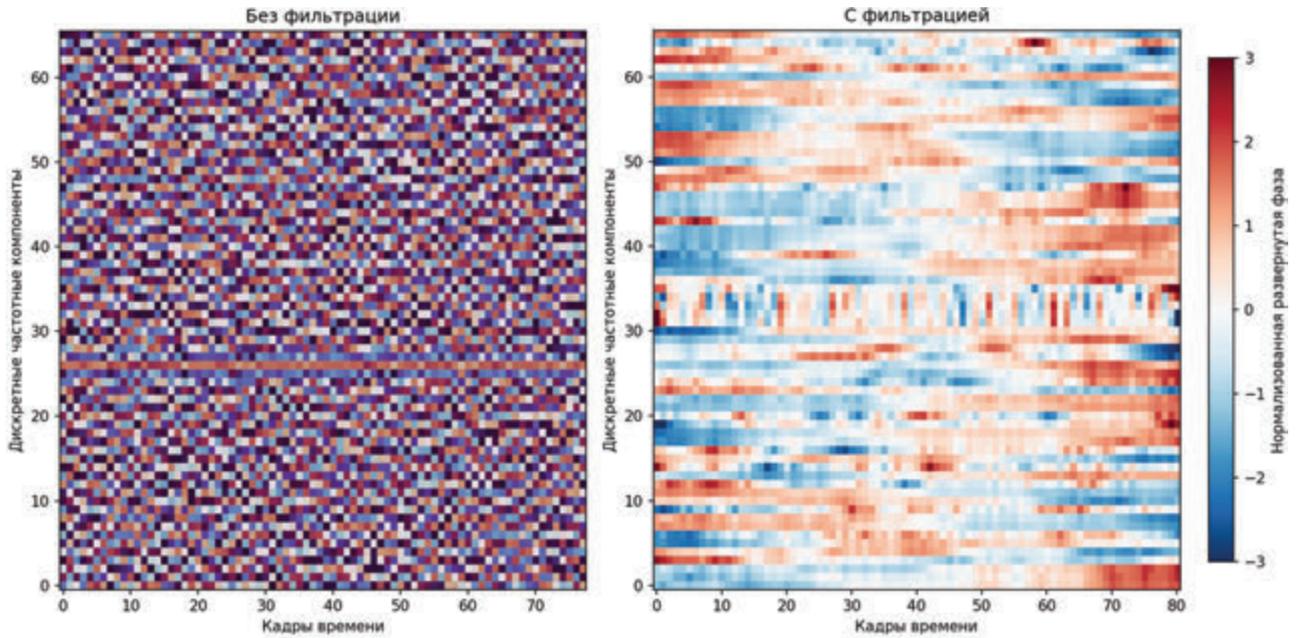


Рис. 2. Развёрнутая и нормализованная фазовая составляющая оконного преобразования Фурье до и после предварительной обработки при SNR = 20 дБ

$$X = [X_1(t, f), X_2(t, f), \dots, X_m(t, f), \dots, X_M(t, f)]^T,$$

где $X \in \mathbb{C}^{M \times T \times F}$ – вектор ОПФ признаков, T – число фреймов, F – дискретные частотные компоненты. Выражение вида:

$$X_m(t, f) = A_m(t, f) \cdot e^{j\psi_m(t, f)}$$

является комплексной компонентой вектора X для данных m , t и f , а $A_m(t, f)$ и $\psi_m(t, f)$ – соответствующие амплитуды и фазы. Далее в предложенном методе в качестве входного признака для обучения используется только фазовая составляющая, где $F = \frac{N}{2} + 1$ может быть вплоть до частоты Найквиста.

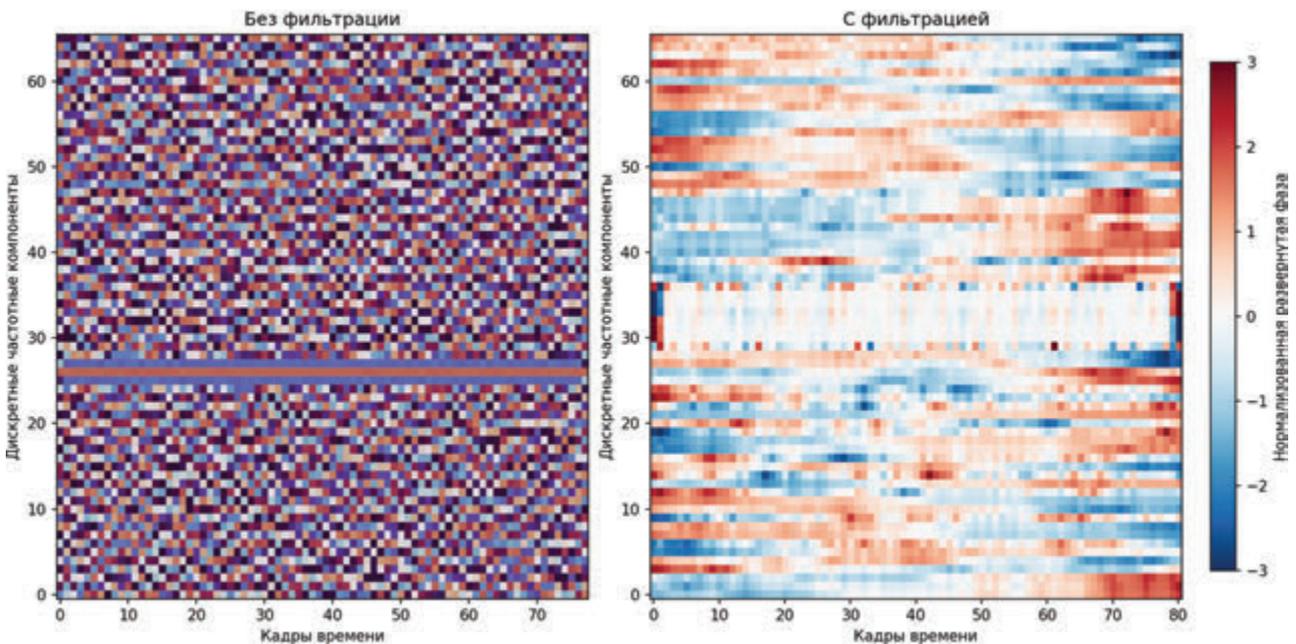


Рис. 3. Развёрнутая и нормализованная фазовая составляющая оконного преобразования Фурье до и после предварительной обработки при SNR = 40 дБ

■ Конфигурация нейронной сети CNN-TCN

Для оценки направления прихода сигнала предлагается нейронная сеть, объединяющая сверточную нейронную сеть (CNN) для пространственно-частотной обработки фазовых признаков и временную сверточную нейронную сеть (TCN) для моделирования их временной динамики. В отличие от традиционных рекуррентных архитектур, использование временных сверточных сетей позволяет эффективнее извлекать признаки из длинных последовательностей данных за счет расширяющегося поля зрения и параллельных вычислений [7]. Подобные подходы уже успешно применяются для локализации морских биологических объектов в реальном времени [8]. На рис. 4 представлена визуализация архитектуры нейронной сети. В отличие от классических CRNN-подходов [9] использующих рекуррентные слои, в данной работе применяется полностью сверточная временная модель CNN-TCN, обеспечивающая более стабильное обучение и высокую вычислительную эффективность. Архитектура состоит из трёх основных компонентов:

1. CNN-блок для извлечения пространственно-частотных признаков из фазовых карт ОПФ;
2. TCN-блок для анализа временной структуры признаков;
3. Регрессионное ядро для оценки параметра направления прихода.

На вход сети подаются данные развёрнутой фазы с размерностями матриц $M \times F \times T$.

Сверточная часть сети предназначена для извлечения локальных пространственно-частотных зависимостей между элементами массива. Она включает несколько двумерных сверточных слоёв с ядрами 3×3 , за которыми выполняются нормализация и функция активации ReLU. Для уменьшения размерности по частотной оси используется выборка максимальных значений, при этом временное разрешение сохраняется. В результате CNN-блок формирует компактное представление признаков, инвариантное к локальным спектральным флуктуациям и устойчивое к шуму, что особенно важно при обработке фазовых данных в условиях подводного распространения.

Для моделирования временной динамики фазовых признаков используется TCN, состоящая из нескольких остаточных блоков с одномерными свёртками по времени. Остаточные соединения обеспечивают стабильность обучения и позволяют учитывать как краткосрочные, так и долгосрочные временные зависимости. По сравнению с рекур-

рентными слоями, TCN не подвержена проблемам затухающих градиентов и допускает эффективную параллельную обработку временных последовательностей. Выход TCN агрегируется по временной оси и подаётся на полносвязный слой, формирующий скалярную оценку направления $U = \sin(\theta)$.

Выбор параметра $U = \sin(\theta)$ обусловлен его линейной связью с межэлементными фазовыми сдвигами в антенной решетке. Итоговая угловая оценка восстанавливается как $\hat{\theta} = \arcsin(\hat{U})$ с последующим ограничением в однозначном угловом секторе. Предложенная CNN-TCN архитектура обладает следующими преимуществами:

- 1) физическая согласованность с моделью сигнала за счёт регрессии по $U = \sin(\theta)$;
- 2) эффективное моделирование временной структуры фазовых признаков без использования рекуррентных слоёв;
- 3) высокая вычислительная эффективность и пригодность для обработки в реальном времени;
- 4) повышенная устойчивость к шуму и многолучевому распространению.



Рис. 4. Визуализация архитектуры нейронной сети CNN-TCN

■ Параметры входных признаков и обучение

В работе были использованы нормированные развернутые фазовые картины ОПФ в качестве входных гидроакустических признаков для предлагаемой гибридной архитектуры CNN-TCN. Принятые в работе параметры входного сигнала, поступающего на апертуру массива сенсоров, были выбраны следующими: длительность сигналов составила 0,5 с при частоте дискретизации 5000 Гц, длина кадра ОПФ – 26 мс с длиной перехода 13 мс в окне Ханна. Для сигналов с каждого канала приемного массива размер ОПФ-фазы составил 65×24 . Для обучения был использован оптимизатор Adam с начальной скоростью обучения 0.001 с уменьшающим коэффициентом 0.95 для каждой второй эпохи в обеих стадиях обучения. Размер выборки составил 64. Обучение производилось в два этапа:

1. 30 эпох с SNR, распределенным в диапазоне от 30 дБ до 35 дБ и скоростью обучения 0.001
2. 100 эпох с SNR, распределенным в диапазоне от 10 дБ до 35 дБ и скоростью обучения 0.0005

■ Оценка производительности

Для определения эффективности предложенного в работе метода оценки угловых координат источников излучения гидроакустического сигнала при помощи линейного однородного массива гидрофонов был выбран показатель среднеквадратичной ошибки (RMSE), который формулируется как:

$$RMSE = \sqrt{\frac{1}{N} \sum_{n=1}^N \|\theta_n - \hat{\theta}_n\|_2^2},$$

где N — количество тестовых выборок, θ_n — истинный угол n -й выборки, $\hat{\theta}_n$ — оценочный угол n -й выборки. Среднеквадратическая ошибка рассчитывается как среднее значение 500 выборок для всех углов от -70° до 70° . Также рассчитывается показатель средней абсолютной ошибки (MAE — Mean Absolute Error), которая является метрикой качества регрессионных моделей, вычисляющая среднее арифметическое модулей разностей между прогнозируемыми и фактическими значениями. Она измеряется в тех же единицах, что и целевая переменная, что обеспечивает простую интерпретацию: чем меньше MAE, тем точнее модель при ее устойчивости к выбросам.

■ Сравнение CRNN и CNN-TCN моделей для оценки угловых координат

В этом разделе представлены результаты сравнения различных методов оценки DoA, чтобы сделать выводы об эффективности предложенной в работе архитектуры. В качестве опорного подхода был выбран метод, основанный на применении CRNN модели с рекуррентными слоями и предложенный в [6]. В ходе экспериментов выполнено сравнение двух архитектур для регрессии направления прихода: CNN-TCN (сверточная модель для временных зависимостей) и CRNN (сверточная модель с рекуррентными блоками). Обучение и тестирование проводились на синтетических данных, сформированных с использованием акустической модели Bellhop. В качестве входных признаков использовалась развернутая фаза, полученная из ОПФ после полосовой предобработки. На рис. 5–8 показаны значения функций потерь, которые являются безразмерными величинами и показывают насколько модель отклоняется от фактических значений в зависимости от эпохи обучения (Функция потерь/эпоха). А также на данных рисунках приведена зависимость показателя средней абсолютной ошибки, выраженной в градусах, от эпохи (MAE/эпоха) для всех этапов обучения и для каждой архитектуры нейронной сети, участвующей в обучении.

По итогам настройки на обучающей выборке с SNR в диапазоне от 10 дБ до 35 дБ модель CNN-TCN показала более высокое качество со следующими результатами по абсолютной ошибке определения угла и среднеквадратической ошибке:

- 1) для CNN-TCN средние значения (MAE/RMSE) составили $1^\circ/1.4^\circ$;
- 2) для CRNN средние значения (MAE/RMSE) составили $1^\circ/1.5^\circ$.

Аналогичная тенденция наблюдается на тестировании по уровням SNR от -5 до 40 дБ (рис. 9):

- 1) для CNN-TCN средние значения (MAE/RMSE) составили $1.5^\circ/2.44^\circ$;
- 2) для CRNN показатель MAE $1.6^\circ/2.6^\circ$.

Важно также отметить, что значения SNR в диапазонах $[-5 \text{ дБ} \dots 10 \text{ дБ}]$ и $[35 \text{ дБ} \dots 40 \text{ дБ}]$ находятся вне диапазона SNR, использованного на этапе настройки $[+10 \text{ дБ} \dots +35 \text{ дБ}]$, и поэтому их следует трактовать как проверку экстраполяции. В частности, на значении SNR 40 дБ качество не является наилучшим среди всех уровней SNR, что согласуется с тем, что модель не оптимизировалась под данное условие, несмотря на “высокий” уровень сигнала. В целом наблюдаемая зависимость качества от SNR носит ожидаемый характер: при снижении SNR ошиб-

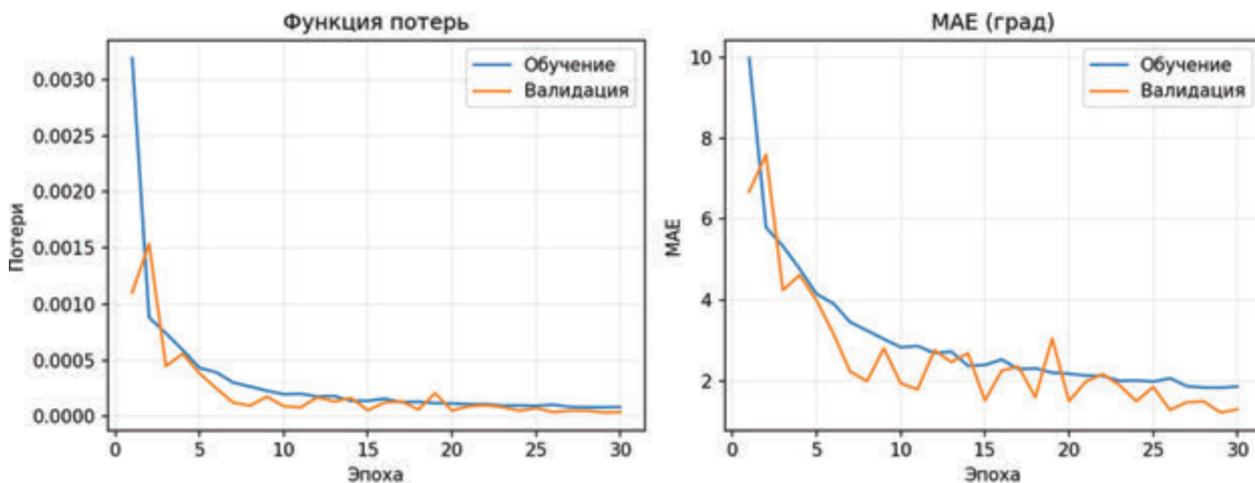


Рис. 5. Графики зависимостей функции потерь и абсолютной ошибки от эпох обучения для архитектуры CRNN на 1-й стадии обучения

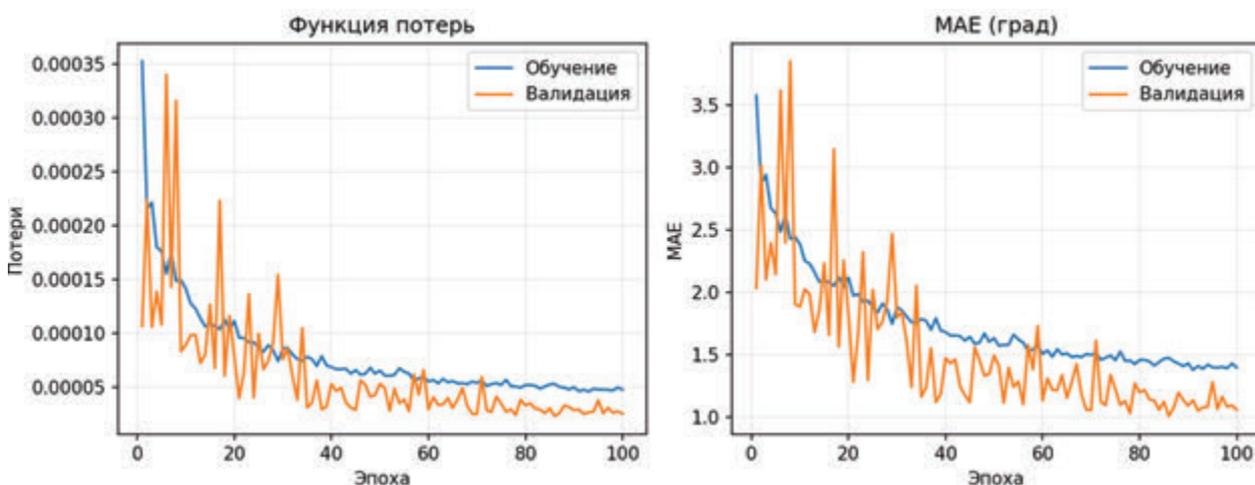


Рис. 6. Графики зависимостей функции потерь и абсолютной ошибки от эпох обучения для архитектуры CRNN на 2-й стадии обучения

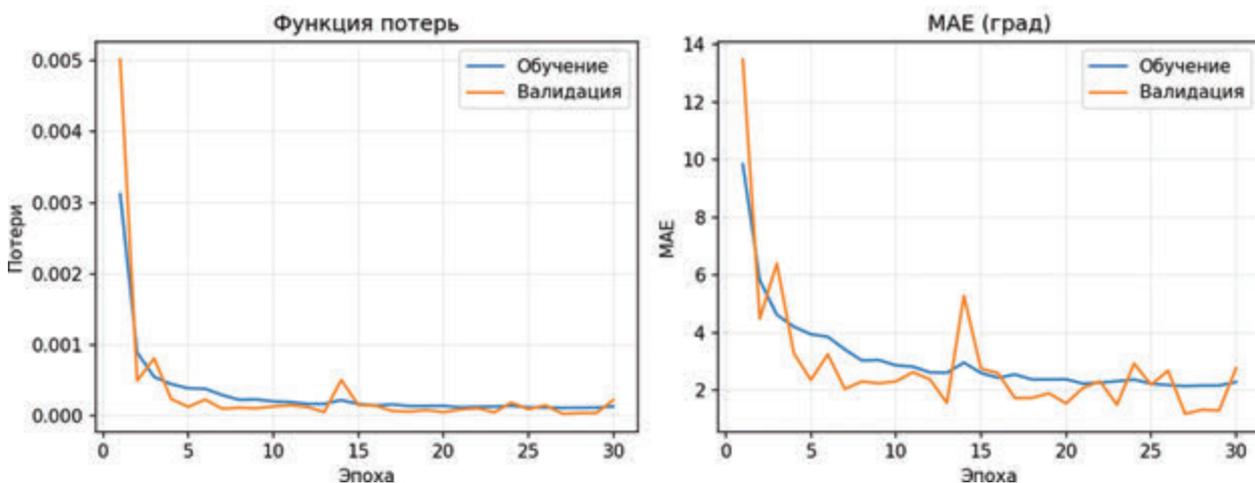


Рис. 7. Графики зависимостей функции потерь и абсолютной ошибки от эпох обучения для архитектуры CNN-TCN на 1-й стадии обучения

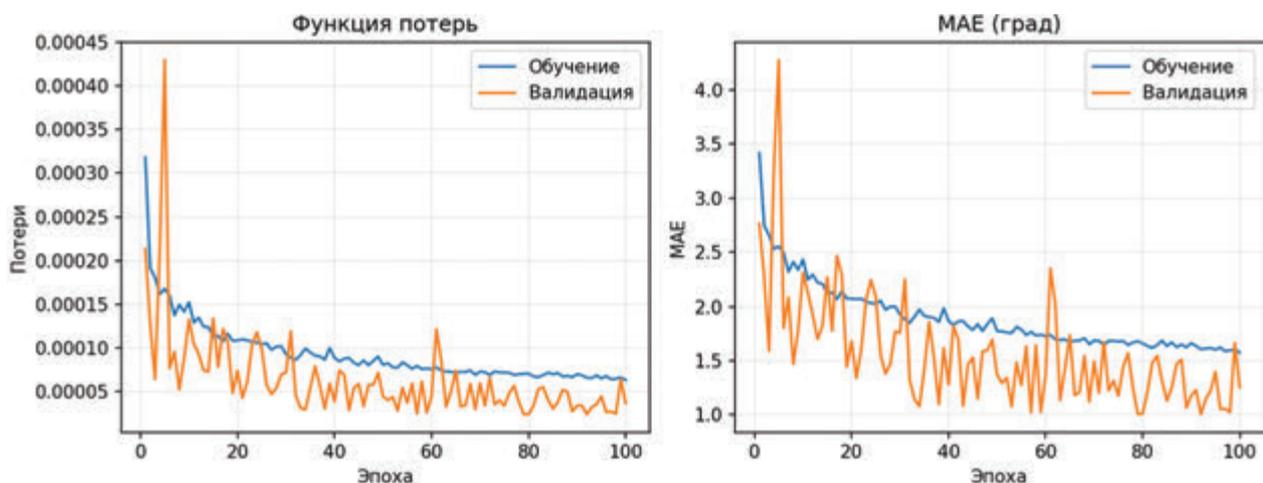


Рис. 8. Графики зависимостей функции потерь и абсолютной ошибки от эпох обучения для архитектуры CNN-TCN на 2-й стадии обучения

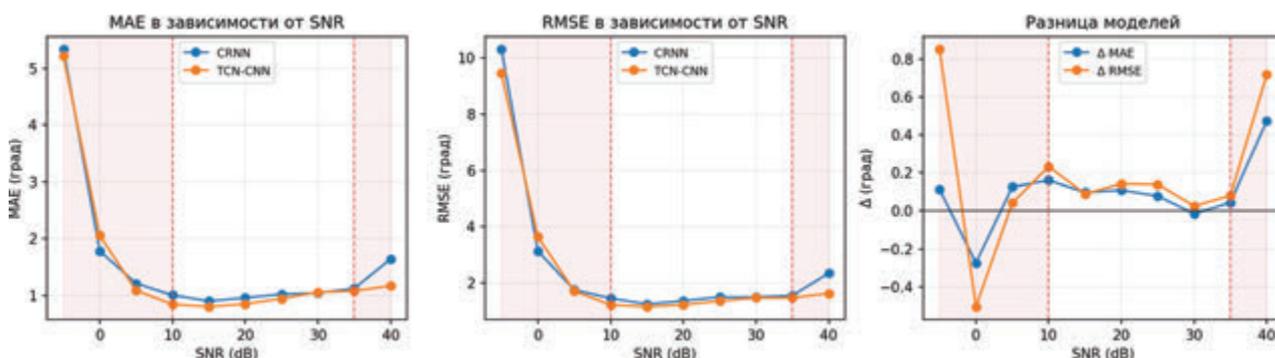


Рис. 9. Графики зависимости MAE/RMSE от SNR

ки возрастают, причём существеннее в наиболее шумных режимах. В сравнении с упомянутыми ранее классическими методами определения угловых координат источников излучения, способы, основанные на применении заранее обученных нейронных сетей, показывают наилучшие результаты только в том диапазоне SNR, в котором происходило обучение.

Заключение

С практической точки зрения результаты, представленные на рис. 9, показывают, что синтетические данные, полученные на основе гидроакустического симулятора Bellhop, могут служить воспроизводимой и контролируемой платформой для сравнения нейросетевых архитектур в задаче DoA и анализа устойчивости к шуму. В рамках рассмотренных условий нейроструктура CNN-TCN демонстрирует более стабильное качество и лучшее обобщение по уровню SNR в сравнении с CRNN. Вместе с тем переносимость выводов на реальные измерения и другие сценарии среды требует отдельной валидации, поскольку

ку синтетическая генерация фиксирует конкретный набор предположений о характеристиках канала.

Важной особенностью нейроструктуры CNN-TCN является реализация обработки временных рядов через одномерные свертки, которые эффективно распараллеливаются по временным кадрам и эффективнее используют вычислительные мощности ЭВМ. В свою очередь, для моделей типа CRNN временная агрегация выполняется рекуррентными блоками, где вычисления на текущем шаге зависят от предыдущего состояния, что ограничивает степень параллелизма и увеличивает накладные расходы на обучение. Поэтому даже при сопоставимом качестве на валидации, что видно на графиках выше, нейроструктура CNN-TCN, как правило, демонстрирует меньшую длительность эпохи и более короткое общее время обучения.

Использование временных сверточных сетей (CNN-TCN) позволяет модели извлекать долгосрочные зависимости. Это дает основание полагать, что при увеличении времени накопления сигнала точность оценки углов прихода DoA будет сохраняться или расти за счет усреднения шумов, что подтверждает

ет масштабируемость предложенного подхода по времени.

Методика формирования обучающей выборки на основе моделирования лучевых траекторий в среде Bellhop охватывает физические принципы распространения звука, не ограниченные конкретным узким частотным диапазоном. Следовательно, при условии адаптации шага антенной решетки к новой длине волны, веса предобученной нейронной сети могут быть эффективно использованы или экстраполированы на смежные частотные диапазоны с минимальной потерей точности.

Важно отметить, что в отличие от классических методов, которые сильно деградируют при изменении параметров среды без перенастройки, нейросетевые архитектуры обучаются извлекать структуру задержек лучей, что делает их более устойчивыми к смене условий эксплуатации.

Репозиторий с исходными кодами программ и скриптов, а также конфигурационными файлами и документацией по их использованию доступен по ссылке [10].

Финансирование: Данная работа выполнена в рамках государственного задания Минобрнауки России в сфере научной деятельности по проекту № FZNS-2026-0007.

СПИСОК ИСТОЧНИКОВ

- Schmidt R. Multiple emitter location and signal parameter estimation // IEEE Transactions on Antennas and Propagation. 1986. Vol. 34. No. 3. P. 276–280.
- Van Trees H.L. Optimum Array Processing (Detection, Estimation, and Modulation Theory) Part IV, Wiley-Interscience, 2002.
- Xiao X., Zhao S., Zhong X., Jones D.L., Chng E.S., Li H. A learning-based approach to direction of arrival estimation in noisy and reverberant environments // 2015 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). South Brisbane, QLD, Australia. 2015. P. 2814–2818.
- Chakrabarty S., Habets E.A.P. Broadband doa estimation using convolutional neural networks trained with noise signals // 2017 IEEE Workshop on Applications of Signal Processing to Audio and Acoustics (WASPAA), New Paltz, NY, USA. 2017. P. 136–140.
- Wang L., Zhang Y., Liu S., Chen H. Underwater acoustic vector DOA estimation in hybrid noise environments based on sparsely gated mixture-of-experts mechanism // Sci. Rep. 2026. Vol. 16, No. 1. P. 442.
- Porter M.B. The BELLHOP Manual and User's Guide: PRELIMINARY DRAFT. Heat, Light, and Sound Research, Inc., 2011.
- Li X., Chen J., Bai J., Ayub M.S., Zhang D., Wang M., Yan Q. Deep learning-based DOA estimation using CRNN for underwater acoustic arrays // Frontiers in Marine Science. 2022. Vol. 9.
- Zhou Y., Wang X. Parallel Net: Frequency-Decoupled Neural Network for DOA Estimation in Underwater Acoustic Detection // J. Mar. Sci. Eng. 2025. Vol. 13, No. 2. P. 210.
- DSPACE@MIT. Automatic Baleen Whale Detection and 2D Localization Using a Temporal Convolutional Network (TCN). Technical Report, Massachusetts Institute of Technology, 2025.
- <https://gitlab.com/NikitaS2001/deep-doa-underwater-paper>

Справка об авторах:

БОБРОВ Владислав Витальевич, магистр, доцент
Место работы: Дальневосточный федеральный университет, Политехнический институт, Департамент электроники, телекоммуникации и приборостроения
Адрес места работы: 690922, Приморский край, г. Владивосток, о-в Русский, п. Аякс, 10
Область научных интересов: цифровая связь и навигация, цифровая обработка сигналов
E-mail: bobrov_vv@dvfu.ru

СМАДЫЧ Никита Сергеевич, магистр
Место работы: Дальневосточный федеральный университет, Политехнический институт, Департамент электроники, телекоммуникации и приборостроения
Адрес места работы: 690922, Приморский край, г. Владивосток, о-в Русский, п. Аякс, 10
Область научных интересов: машинное обучение, связь и навигация, цифровая обработка сигналов
E-mail: smadych.ns@dvfu.ru

РОДИОНОВ Александр Юрьевич, доктор технических наук, зав. лабораторией
Место работы: ИПМТ ДВО РАН
Адрес места работы: Россия, 690091, г. Владивосток, ул. Суханова, д.5а
Область научных интересов: цифровая связь и навигация, цифровая обработка сигналов
E-mail: deodar1618@yandex.ru
ORCID: 0000-0003-2931-900X

ЗИНЧЕНКО Дмитрий Владимирович, магистр
Место работы: Дальневосточный федеральный университет, Политехнический институт, Департамент электроники, телекоммуникации и приборостроения
Адрес места работы: 690922, Приморский край, г. Владивосток, о-в Русский, п. Аякс, 10
Область научных интересов: робототехника, цифровая связь, обработка сигналов
E-mail: zinchenko.dv@dvfu.ru

Для цитирования:

Бобров В.В., Смадыч Н.С., Родионов А.Ю., Зинченко Д.В. ПРИМЕНЕНИЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ОЦЕНКИ НАПРАВЛЕНИЯ ПРИХОДА СИГНАЛА В ПОДВОДНОЙ СРЕДЕ // Подводные исследования и робототехника. 2026. № 1 (55). С. 49–58. DOI: 10.37102/1992-4429_2026_55_01_05. EDN: SHOTYO.



APPLICATION OF ARTIFICIAL NEURAL NETWORKS TO ESTIMATE THE DIRECTION OF SIGNAL ARRIVAL IN AN UNDERWATER ENVIRONMENT

V.V. Bobrov, N.S. Smadych, A.Yu. Rodionov, D.V. Zinchenko

The article discusses approaches to solving the problem of spatial localization of sound sources in the underwater environment, as one of the fundamental challenges of modern hydroacoustics. Limitations of classical algorithms for estimating signal direction (Direction of Arrival) in passive monitoring, underwater navigation, and environmental control systems are analyzed. More efficient methods of direction finding using modern architectures of artificial neural networks are considered. A method for obtaining a set of synthetic data for deep learning of neural networks of various architectures using a computer simulation of a hydroacoustic communication channel in the BELLHOP programs presented. The results of modeling a linear array of hydrophones are presented and the data obtained are analyzed. In conclusion, approaches to improving the resolution and efficiency of the considered method are proposed.

Keywords: neural networks, artificial intelligence, deep learning, linear antenna arrays, simulation, hydroacoustics

References

- Schmidt R. Multiple emitter location and signal parameter estimation // IEEE Transactions on Antennas and Propagation. 1986. Vol. 34. No. 3. P. 276–280.
- Van Trees H.L. Optimum Array Processing (Detection, Estimation, and Modulation Theory) Part IV, Wiley-Interscience, 2002.
- Xiao X., Zhao S., Zhong X., Jones D.L., Chng E.S., Li H. A learning-based approach to direction of arrival estimation in noisy and reverberant environments // 2015 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). South Brisbane, QLD, Australia. 2015. P. 2814–2818.
- Chakrabarty S., Habets E.A.P. Broadband doa estimation using convolutional neural networks trained with noise signals // 2017 IEEE Workshop on Applications of Signal Processing to Audio and Acoustics (WASPAA), New Paltz, NY, USA. 2017. P. 136–140.
- Wang L., Zhang Y., Liu S., Chen H. Underwater acoustic vector DOA estimation in hybrid noise environments based on sparsely gated mixture-of-experts mechanism // Sci. Rep. 2026. Vol. 16, No. 1. P. 442.
- Porter M.B. The BELLHOP Manual and User's Guide: PRELIMINARY DRAFT. Heat, Light, and Sound Research, Inc., 2011.
- Li X., Chen J., Bai J., Ayub M.S., Zhang D., Wang M., Yan Q. Deep learning-based DOA estimation using CRNN for underwater acoustic arrays // Frontiers in Marine Science. 2022. Vol. 9.
- Zhou Y., Wang X. Parallel Net: Frequency-Decoupled Neural Network for DOA Estimation in Underwater Acoustic Detection // J. Mar. Sci. Eng. 2025. Vol. 13, No. 2. P. 210.
- DSpace@MIT. Automatic Baleen Whale Detection and 2D Localization Using a Temporal Convolutional Network (TCN). Technical Report, Massachusetts Institute of Technology, 2025.
- <https://gitlab.com/NikitaS2001/deep-doa-underwater-paper>

Information about the authors

BOBROV Vladislav Vitalievich, Master's degree, Associate Professor

Place of work: Far Eastern Federal University, Polytechnic Institute, Department of Electronics, Telecommunications, and Instrumentation

Work address: 690922, Vladivostok, Russian Island, Ajax village, 10

Research interests: digital communications and navigation, digital signal processing

E-mail: bobrov_vv@dvf.u.ru

SMADYCH Nikita Sergeevich, Master's degree

Place of work: Far Eastern Federal University, Polytechnic Institute, Department of Electronics, Telecommunications, and Instrumentation

Work address: 690922, Vladivostok, Russian Island, Ajax village, 10

Research interests: machine learning, communications and navigation, digital signal processing

Email: smadych.ns@dvf.u.ru

RODIONOV Alexandr Yurievich, Head of the laboratory, Doctor of Technical Sciences

Name of institution: IMTP FEB RAS

Work address: Russia, 690091, Vladivostok, st. Sukhanova, 5a

Research interests: digital communication and navigation, digital signal processing

E-mail: deodar1618@yandex.ru

ORCID: 0000-0003-2931-900X

ZINCHENKO Dmitry Vladimirovich, Master's degree

Place of work: Far Eastern Federal University, Polytechnic Institute, Department of Electronics, Telecommunications, and Instrumentation

Work address: 690922, Vladivostok, Russian Island, Ajax village, 10

Research interests: robotics, digital communication, and signal processing

Email: zinchenko.dv@dvf.u.ru