DOI: https://doi.org/10.30898/1684-1719.2026.9.15
УДК: 621.391

Анализ различных нейросетевых алгоритмов для оценки длительности радиосигнала с неизвестными амплитудой, частотой и начальной фазой

Нгуен Ван Тхю, Ю.Э. Корчагин

Воронежский государственный университет,
Россия, Воронеж

Статья поступила в редакцию 27 августа 2026 г.

Аннотация. В работе выполнен сравнительный анализ ряда нейросетевых методов, предназначенных для оценки длительности радиосигналов с огибающей произвольной формы в условиях априорной неопределенности по амплитуде, начальной фазе и несущей частоте. Получены статистические характеристики квазиправдоподобной оценки длительности радиосигнала. Проведена оценка эффективности различных архитектур нейронных сетей при изменении условий обработки сигнала. Установлено, что точность оценки длительности определяется не только особенностями архитектуры нейронной сети, но и способом формирования обучающей выборки. Наиболее высокие показатели показали сверточные нейронные сети, особенно при использовании дискретного представления входных данных в частотно-временной области. В то же время полносвязная нейронная сеть характеризуется ограниченной способностью к извлечению информативных признаков сигнала. Показано что применение автоэнкодера в качестве средства предварительного подавления белого шума способствует повышению точности оценки длительности радиосигнала.

Ключевые слова: квазиправдоподобный алгоритм, нейросетевой алгоритм, оценка длительности, сверточная нейронная сеть, многослойный перцептрон, автоэнкодер, неизвестная частота, длительность, начальная фаза, радиосигнал.

Финансирование: Исследование выполнено за счет гранта Российского научного фонда № 24-19-00891, https://rscf.ru/project/24-19-00891/

Автор для переписки: Нгуен Ван Тхю, thuynguyenvan59395@gmail.com

Введение

Для широкого круга практических приложений в области теории связи, радиолокации, навигации и систем управления важной задачей является определение длительности радиосигнала, наблюдаемого на фоне шума. В научной литературе было имеется значительное количество работ, посвященных разработке статистических методов синтеза и анализа алгоритмов оценивания длительности, а также снижению погрешностей в процессе оценивания [1-4]. Были разработаны различные подходы, направленные на повышение точности оценивания и адаптацию к различным априорным условиям при оценке длительности радиосигналов. В частности, метод максимального правдоподобия, использованный в работе [1], позволяет достичь высокой точности оценивания, однако его практическая реализация, как правило, требует знания ряда априорных параметров сигнала. Квазиправдоподобные методы значительно проще в реализации, однако чувствительны к ошибкам задания неизвестных параметров. В работе [2] показано, что при отклонении оценок амплитуды и фазы от истинных значений наблюдается смещение оценки длительности и значительное увеличение ее рассеяния, достигающее десятков раз. Вышеуказанные ограничения статистических методов свидетельствуют о необходимости поиска альтернативных подходов, позволяющих обеспечить высокую точность оценивания без увеличения сложности технических радиосистем. Искусственные нейронные сети представляют собой перспективный инструмент обработки сигналов благодаря способности автоматически извлекать

информативные признаки из данных и отсутствию необходимости задания полного набора априорных параметров. Указанные преимущества обусловили их широкое распространение в последние годы, вследствие чего методы, основанные на искусственных нейронных сетях, активно используются в исследованиях, посвященных различным задачам обработки сигналов [5–9]. Следует подчеркнуть, что для решения задачи оценки длительности радиосигналов могут использоваться различные архитектуры искусственных нейронных сетей. При этом точность оценивания определяется рядом факторов, ключевым из которых является архитектура нейронной сети. Однако вопросы анализа и сравнительного исследования эффективности различных архитектур нейронных сетей для задачи оценки длительности радиосигналов при неизвестных амплитуде, частоте и начальной фазе на сегодняшний день остаются недостаточно изученными. Следовательно, исследование влияния различных архитектур нейронных сетей на точность оценивания длительности радиосигнала представляет собой важную научно-практическую задачу, решение которой позволяет определить более эффективную структуру нейронной сети и повысить результативность методов оценивания на основе глубокого обучения при наличии априорной неопределенности параметров сигнала. В настоящей работе рассматриваются три архитектуры искусственных нейронных сетей. Первая архитектура представляет собой многослойный персептрон (MLP), вторая архитектура реализована на основе сверточной нейронной сети (CNN), третьей исследуемой нейронной сетью является автоэнкодер.

1. Постановка задачи

Запишем радиосигнал в виде

$$s(t,a,\varphi,\omega,\tau)=\begin{cases} af(t)\cos(\omega t-\varphi), & 0\le t\le \tau,\\ 0, & t<0,\ t>\tau, \end{cases} \quad (1)$$

где $f(t)$ – непрерывная функция, описывающая форму огибающей, a – амплитуда, $\varphi\in[-\pi,\pi]$ – начальная фаза, τ, ω – длительность и частота сигнала, которые принимают значения из априорных интервалов

$$\tau\in[T_1,T_2],\ \omega_0\in[\Omega_1,\Omega_2].$$

Пусть на интервале $[0,T]$ наблюдается реализация

$$\xi(t)=s(t,a_0,\varphi_0,\omega_0,\tau_0)+n(t),$$

представляющая собой сумму полезного сигнала (1) и гауссовского белого шума $n(t)$. Здесь $a_0,\varphi_0,\omega_0,\tau_0$ соответствуют истинным значениям амплитуды, начальной фазы, частоты и длительности сигнала. Предполагается, что белый шум $n(t)$ характеризуется односторонней спектральной плотностью мощности N_0. Требуется построить оценку длительности полезного сигнала (1) при неизвестных амплитуде, частоте и начальной фазе.

2. Квазиправдоподобный алгоритм оценки длительности

При априорной неопределенности длительности, амплитуды, частоты и начальной фазы сигнала логарифм функционала отношения правдоподобия (ФОП) представляет собой функцию четырех неизвестных параметров:

$$L(a,\varphi,\omega,\tau)=\frac{2a}{N_0}\int_0^{\tau} f(t)\cos(\omega t-\varphi)[\xi(t)-af(t)\cos(\omega t-\varphi)/2]dt. \quad (2)$$

Следовательно, имеется априорная параметрическая неопределенность относительно амплитуды, частоты и начальной фазы. Одним из возможных подходов к устранению указанной неопределенности является применение квазиправдоподобного (КП) алгоритма оценки, согласно которому вместо неизвестных амплитуды a, частоты ω и начальной фазы φ в выражении (2)

используются их некоторые ожидаемые значения a^*, ω^*, φ^* соответственно. Согласно работе [2], при равенстве ожидаемых и истинных значений всех неинформативных параметров, квазиправдоподобный алгоритм оценки длительности обладает смещением и рассеянием

$$B = 0, \quad V = 26\tau_0^2 / \rho_0^4, \tag{3}$$

где $\rho_0^2 = a_0^2 \tau_0 f^2(\tau_0) / N_0$.

3. Нейросетевые алгоритмы оценки длительности радиосигнала

Для применения нейронной сети к задаче оценки длительности сигнала предлагается использовать входные данные, сформированные на основе дискретных отсчетов принятой реализации или ее спектрограммы. На интервале $[0, T_2]$ располагается $N = \mathrm{int}(T_2 f_s)$ отсчетов, где f_s – частота дискретизации. В процессе формирования принятой реализации с шагом $\Delta t = 1/f_s$ в моменты времени $t_i = i\Delta t$, $i = \overline{1, N}$ вычислялись отсчеты радиосигнала и белого шума

$$\xi_i = af(t_i)\cos(\omega t_i - \varphi) + n_i.$$

Введем величину $\kappa = \omega_0 T_2 / 2\pi$ – число периодов колебания в импульсе максимально возможной длительности. Величина κ характеризует ширину полосы частот радиосигнала и может быть названа параметром узкополосности. В качестве обучающих данных для различных нейронных сетей предлагается использовать либо дискретные отсчеты принятой реализаций либо ее спектрограммы с целью анализа влияния формы входных данных на точность нейронной сети в задаче оценки длительности. На рис. 1 показаны примеры различных типов входных данных.

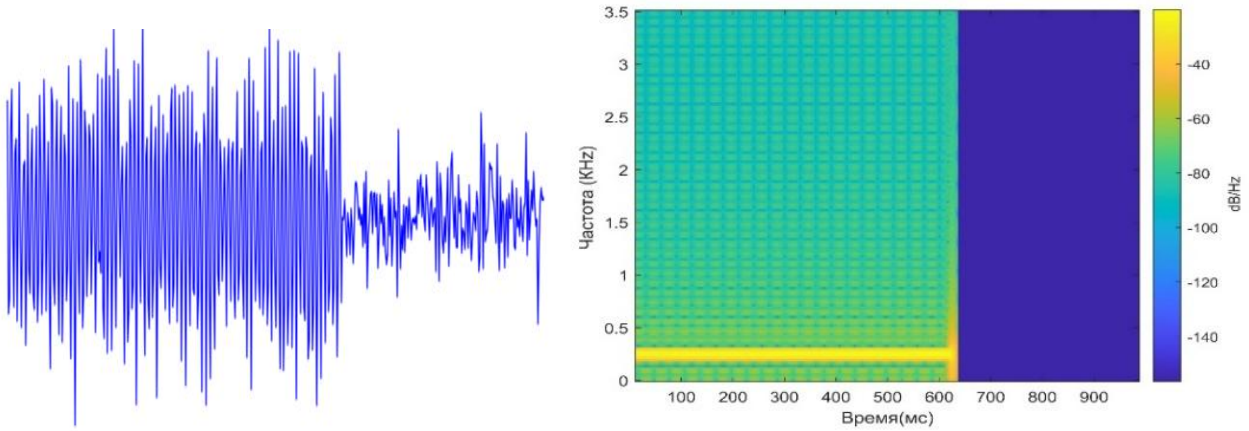


Рис. 1. Пример формы принятой реализации (слева)
и ее спектрограммы (справа).

Обучение выполнялось на основе сгенерированных реализаций смеси сигнала и шума. Обучающая выборка включала 100000 смоделированных реализаций сигнала, наблюдаемых в пределах одного и того же временного интервала. С целью повышения разнообразия обучающего набора данных параметры моделируемого сигнала генерировались случайным образом. В частности, амплитуда принимала значения в диапазоне от 0,1 до 5, а параметр κ случайным образом выбирался в диапазоне [50,80]. Для каждой реализации к сигналу добавлялся шум, ширина полосы частот которого была выбрана вдвое большей по сравнению с шириной полосы частот сигнала, а значение отношения сигнал/шум (ОСШ) случайным образом выбиралось из диапазона от 0,1 до 12. Реализация сигнала с добавленным шумом использовалась в качестве входных данных нейронной сети, тогда как соответствующее значение длительности сигнала после преобразования с использованием натурального логарифма применялось в качестве целевой регрессионной метки. Обучающая и валидационная выборки формировались в соотношении 80 процентов и 20 процентов соответственно, что обеспечивало возможность контроля возникновения эффекта переобучения в процессе обучения модели. Обучение осуществлялось на обучающем наборе данных с максимальным числом эпох, равным 100, при размере пакета составляющем 64. Для оценки способности модели к обобщению в ходе обучения использовался валидационный набор данных.

После обучения модели было выполнено статистическое моделирование нейросети путем расчета нормированных смещения $b = \langle \hat{\tau} - \tau_0 \rangle / \tau_0$ и рассеяния $v = \langle (\hat{\tau} - \tau_0)^2 \rangle / \tau_0^2$, где $\hat{\tau}$ – оценка, сформированная нейросетью. В ходе моделирования на каждом испытании с номером m формировалась входная реализация, выполнялось ее преобразование нейросетью, вычислялась оценка длительности $\hat{\tau}_m$, накапливались ошибки оценки

$$\sum_{m=1}^{N} (\hat{\tau}_m - \tau_0), \quad \sum_{m=1}^{N} (\hat{\tau}_m - \tau_0)^2$$

и вычислялись выборочные значения смещения и рассеяния

$$b = \frac{1}{N\tau_0} \sum_{m=1}^{N} (\hat{\tau}_m - \tau_0), \; v = \frac{1}{\tau_0^2 N} \sum_{m=1}^{N} (\hat{\tau}_m - \tau_0)^2 .$$

Всего было реализовано $N = 10^6$ циклов испытаний.

3.1. Многослойный персептрон

Первой архитектурой нейронной сети, исследуемой в настоящей работе, является многослойный персептрон. Несмотря на то что MLP не относится к специализированным архитектурам, предназначенным для обработки временных последовательностей, поскольку не обладает механизмом непосредственного моделирования последовательных зависимостей между наблюдениями, анализ эффективности данной архитектуры представляет научный интерес. В настоящем исследовании MLP используется в качестве базовой модели, что обеспечивает возможность объективного сравнения эффективности более современных архитектур искусственных нейронных сетей, таких как CNN и автоэнкодер. С целью повышения аппроксимирующей способности модели в настоящей работе предлагается использовать несколько скрытых слоев MLP. Предполагается, что увеличение глубины сети позволит формировать внутренние представления более высокого уровня абстракции, благодаря чему будет обеспечено более точное моделирование нелинейных

зависимостей между входными признаками. Типовая архитектура многослойного персептрона представлена на рис. 2.

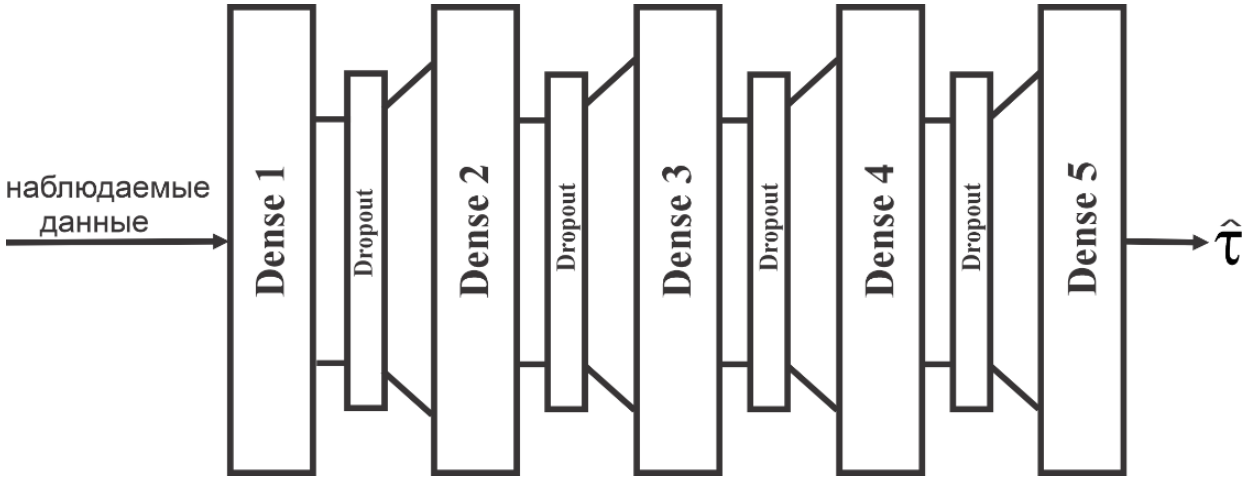


Рис. 2. Блок-схема нейросети многослойного персептрона.

Модель нейронной сети разработана на основе многослойного персептрона и реализована с использованием библиотеки TensorFlow/Keras в рамках последовательной архитектуры. Архитектура сети включает пять полносвязных слоев (Dense) с количеством нейронов 128, 64, 32, 16 и 1 соответственно. Во всех скрытых слоях применяется функция активации ReLU, обеспечивающая эффективное моделирование нелинейных зависимостей между входными и выходными данными, а также способствующая снижению эффекта затухания градиента в процессе обучения. После каждого скрытого слоя используется слой Dropout с коэффициентом 0,1, обеспечивающий случайное отключение 10 % нейронов при каждом обновлении весовых коэффициентов. Применение данного механизма позволяет уменьшить риск переобучения, повысить обобщающую способность модели при обработке ранее не наблюдавшихся данных и одновременно сохранить возможность извлечения наиболее значимых признаков без существенной потери полезной информации. Выходной слой Dense5 состоит из одного нейрона с линейной функцией активации. Такая конфигурация соответствует задачам регрессии, в которых целью модели является прогнозирование непрерывной величины, а не вероятности принадлежности к классу или категориальной метки. Постепенное уменьшение количества нейронов в скрытых слоях обеспечивает

последовательное выявление сложных нелинейных зависимостей, извлечение и компактное представление информативных признаков входных данных, а также формирование их высокоуровневого представления, что, в свою очередь, способствует повышению точности прогнозирования длительности выходного сигнала. Для оптимизации процесса обучения нейронной модели использовался алгоритм Adam, а в качестве функции потерь применялась среднеквадратичная ошибка (MSE), обеспечивающая оценку расхождения между прогнозируемыми и фактическими значениями выходного параметра.

3.2. Одномерная сверточная нейронная сеть

Одномерная сверточная нейронная сеть (1D-CNN) является эффективным методом анализа и обработки одномерных сигналов и широко применяется в многочисленных исследованиях, представленных в научной литературе [10-12]. Благодаря механизму свертки с использованием специализированных фильтров признаков модель 1D-CNN способна автоматически извлекать значимые характеристики сигнала и его шумовой составляющей на различных уровнях представления. Данная особенность обеспечивает адаптивность модели к различным задачам анализа и обработки сигналов, а также способствует повышению эффективности процедур распознавания, оценки параметров и извлечения полезной информации из входных данных. Схема архитектуры разработанной нейронной сети представлена на рис. 3.

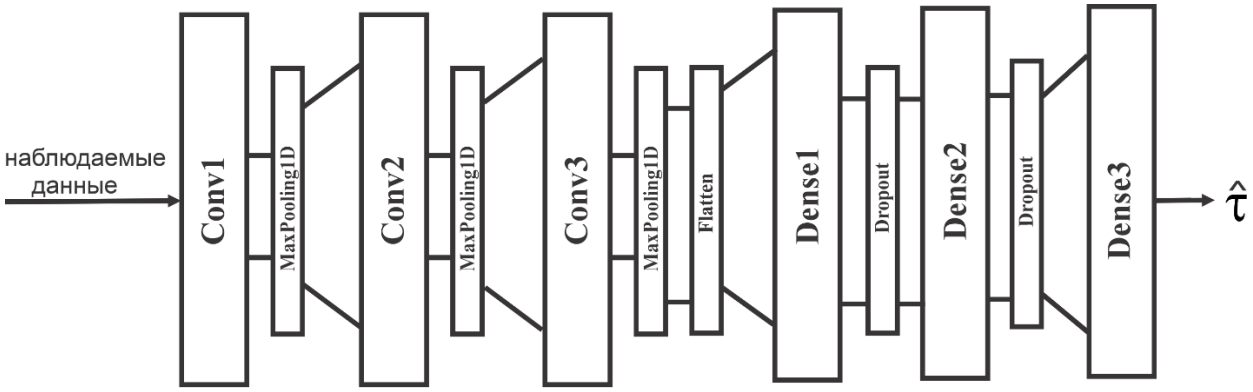


Рис. 3. Блок – схема одномерной сверточной нейросети.

Модель реализована на основе последовательной архитектуры одномерной сверточной нейронной сети для извлечения признаков из последовательных сигналов. Архитектура включает три сверточных блока с числом фильтров 32, 64 и 128, размером ядра 11 и функцией активации ReLU; при этом используется параметр “padding same” для сохранения временной размерности признаков. После каждого сверточного слоя применяется одномерный слой прореживания (MaxPooling1D) с размером pooling 2, что обеспечивает снижение размерности данных при сохранении наиболее информативных характеристик сигнала. Полносвязная часть модели включает слой Flatten для преобразования признаков в одномерный вектор, за которым следуют два слоя Dense с 128 и 32 нейронами и функцией активации ReLU. После каждого слоя Dense применяется Dropout с коэффициентом 0,1 для уменьшения переобучения и повышения обобщающей способности модели. Выходной слой состоит из одного нейрона с линейной функцией активации, что соответствует задаче регрессии. В ходе обучения модели использовался алгоритм оптимизации Adam, при этом в качестве функции потерь использовалась MSE.

3.3. Двумерная сверточная нейронная сеть

Далее в данной работе предлагается добавить другой тип обучающих данных для модели глубокого обучения, формируемый путем преобразования вектора дискретизированных значений реализации в двумерное представление в частотно-временной области. Данный подход направлен на одновременное использование как спектральных, так и временных характеристик сигнала, что позволяет повысить качество моделирования, особенно в условиях сильного шума. Для этого предлагается использовать архитектуру двумерной сверточной нейронной сети (2D-CNN). Структура модели в целом соответствует представленной на рис. 3. Отличие заключается лишь в том, что слои одномерной свертки (Conv1D) и MaxPooling1D заменены соответственно слоями двумерной свертки (Conv2D) размером ядра 3×3 и двумерного прореживания

(MaxPooling2D) с окном 2×2. Такой подход позволяет провести наглядное и объективное сравнение эффективности одномерных и двумерных сверточных сетей в задаче оценки длительности радиосигнала. В процессе обучения модели использовался алгоритм оптимизации Adam с функцией потерь MSE.

3.4. Модель автоэнкодера

Автокодировщик был выбран для сравнения с другими моделями благодаря его способности эффективно обучаться представлениям признаков и высокой адаптивности к зашумленным сигналам. Схема архитектуры автоэнкодера показана на рис. 4.

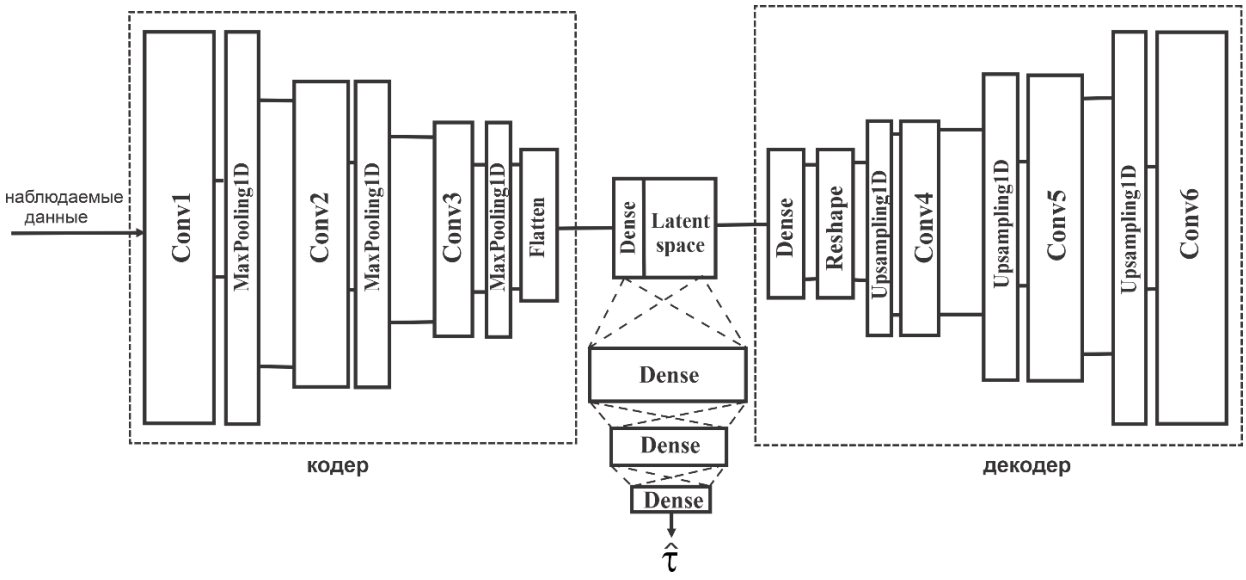


Рис. 4. Блок – схема автоэнкодера.

В отличие от сверточных нейронных сетей и полносвязных нейронных сетей, автоэнкодер не выполняет непосредственную оценку длительности сигнала по его зашумленному спектру. Вместо этого модель сначала обучается восстанавливать спектр незашумленного сигнала по входным данным, содержащим шум. Такой процесс обучения заставляет кодировщик устранять компоненты, обусловленные шумом, сохраняя при этом только ключевые признаки, отражающие сущность сигнала.

Кодировщик получает на вход нормализованную логарифмическую спектрограмму и реализован в виде трех последовательно расположенных сверточных блоков с числом фильтров 16, 32 и 64 соответственно. Во всех

сверточных слоях используются фильтры размером 3×3 и функция активации ReLU, обеспечивающая эффективное нелинейное преобразование входных данных. После каждого сверточного слоя применяется операция MaxPooling2D с размером окна 2×2, направленная на уменьшение размерности признакового пространства при сохранении наиболее значимых характеристик сигнала. Полученное двумерное представление преобразуется в одномерный вектор посредством слоя Flatten и далее проецируется в латентное пространство с помощью полносвязного слоя Dense, формирующего латентный вектор размерностью 128 элементов. Данный вектор служит общим признаковым представлением для задач восстановления спектра сигнала и регрессионной оценки его длительности.

Декодер принимает латентный вектор и восстанавливает пространственную структуру признаков посредством слоя Dense и слоя Reshape. Далее выполняются три последовательных этапа повышения пространственного разрешения с использованием слоев UpSampling2D с размером окна 2×2, каждый из которых сопровождается сверточным слоем, обеспечивающим постепенное восстановление спектра чистого сигнала. Для обеспечения полного соответствия размеров выходного и входного представлений в конце декодера используется слой Cropping2D. Формирование восстановленной логарифмической спектрограммы осуществляется завершающим сверточным слоем с одним фильтром и линейной функцией активации. Таким образом, декодер, обведенный пунктиром на рис. 4, служит для обучения сети автоэнкодера и является вспомогательным с точки зрения оценки длительности. Одновременно латентное представление передается в регрессионную ветвь, состоящую из двух полносвязных слоев Dense с 128 и 32 нейронами соответственно, использующих функцию активации ReLU, после чего линейный выходной слой Dense выполняет оценку длительности сигнала.

В процессе обучения модели для обновления весовых коэффициентов использовался алгоритм оптимизации Adam. Модель была разработана в рамках подхода многозадачного обучения и предусматривала одновременное решение

двух задач: реконструкции входного сигнала и прогнозирования его длительности. В качестве функции потерь для обеих задач использовалась среднеквадратичная ошибка, которая является стандартным критерием для задач регрессии и обеспечивает минимизацию квадратичного отклонения прогнозируемых значений от их эталонных значений. При обучении модели весовой коэффициент функции потерь составлял 0,5 для задачи реконструкции и 1,0 для задачи прогнозирования длительности. Выбранное соотношение весов позволило сместить акцент обучения в сторону повышения точности прогнозирования длительности сигнала, одновременно сохранив эффективность формирования информативных признаковых представлений благодаря задаче реконструкции чистого сигнала. Совместное обучение кодировщика для решения задач восстановления спектра чистого сигнала и регрессионной оценки длительности способствует формированию информативных и устойчивых к шуму латентных представлений. Благодаря этому латентный вектор отражает фундаментальные свойства сигнала, одновременно подавляя влияние шумовых составляющих, что обеспечивает повышение точности и обобщающей способности модели при оценке длительности сигнала, особенно в условиях низкого ОСШ.

4. Результаты анализа эффективности моделей

Для анализа различных нейросетевых алгоритмов в качестве примера будем рассматривать радиосигнала вида

$$f(t) = \sqrt{\frac{2b}{1-e^{-2b}}}\exp\left[-\frac{bt}{T_2}\right],$$

где параметр b характеризует декремент затухания экспоненты. Введем величину $k = T_2 / T_1$, которую будем называть динамическим диапазоном возможных значений длительности.

Введем в рассмотрение величину $z_r^2 = a_0^2 T_2 / N_0$ – ОСШ для прямоугольного радиоимпульса амплитуды a_0 и длительности T_2. Обозначим

$z_0^2 = a_0^2 \int_0^{\tau_0} f^2(t)dt \Big/ N_0$ – отношение ОСШ на выходе приемника МП для сигнала с амплитудой a_0 и длительностью τ_0 Выразим ОСШ z_0^2 для принятого сигнала через ОСШ z_r^2

$$z_0^2 = z_r^2 \frac{e^{-2bx_0} - 1}{e^{-2b} - 1},$$

где $x_0 = \tau_0 / T_2$, $\tau_0 = \frac{T_1 + T_2}{2}$. При обучении нейросетей и моделировании параметр узкополосности выбирался случайно из диапазона $\kappa \in [50,80]$. На рис. 5 и 6 показаны зависимости условных смещения и рассеяния от ОСШ для динамического диапазона $k = 10$ и $b = -0.35$.

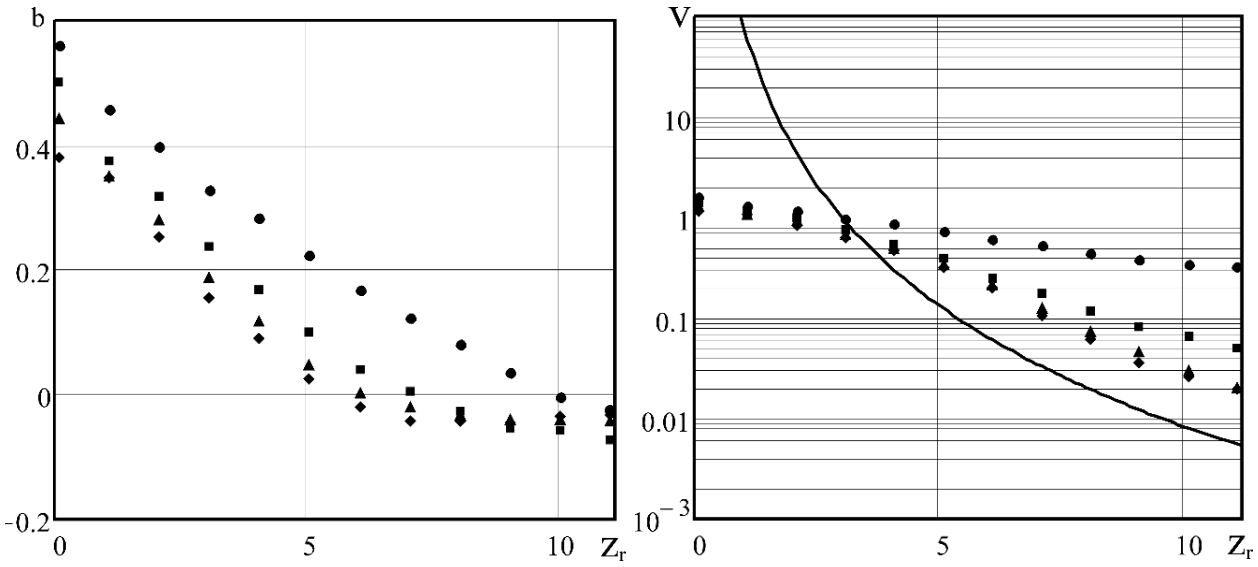


Рис. 5. Зависимость условного смещения (слева)
и рассеяния (справа)от ОСШ.

На рис. 5 представлены условные смещение и дисперсия оценок длительности радиосигнала в зависимости от отношения сигнал/шум. На графиках результаты, полученные с использованием модели автоэнкодера, обозначены ромбиками, модели 2D-CNN – треугольниками, модели 1D-CNN – квадратами и модели MLP – кружками, тогда как сплошная линия соответствует результатам, полученным методом КП при отсутствии расстройки параметров сигнала.

Анализ полученных результатов показывает, что с увеличением ОСШ как смещение, так и дисперсия оценок длительности сигнала закономерно уменьшаются. Однако, скорость снижения ошибок и степень сходимости существенно различаются для рассматриваемых архитектур сети. Среди исследованных моделей глубокого обучения наивысшую точность изображает модель автоэнкодера, что обусловлено его способностью выполнять функцию предварительной обработки данных, обеспечивая эффективное подавление шума перед этапом оценивания длительности. Модель 2D-CNN показывает результаты, близкие к показателям модели автоэнкодера, что свидетельствует о высокой эффективности двумерных сверточных слоев при извлечении информативных признаков, позволяющих надежно различать полезный сигнал и шум. Данный результат также указывает на то, что включение этапа предварительного шумоподавления с использованием автоэнкодера обеспечивает лишь незначительное повышение точности в рассматриваемых условиях моделирования. В свою очередь, модель 1D-CNN также обеспечивает достаточно высокую точность оценивания, однако уступает 2D-CNN, что подтверждает существенное влияние способа представления сигнала, прежде всего в временно-частотной области, на эффективность процесса оценивания. Среди всех исследованных моделей наименее точные результаты показала MLP, что отражает ограниченные возможности полносвязной архитектуры в извлечении высокоинформативных признаков радиосигнала.

Заключение

Алгоритмы оценивания длительности сигнала на основе нейронных сетей в настоящее время уступают по эффективности оптимальным статистическим методам. Однако, их применение является оправданным при отсутствии априорной информации о параметрах сигнала или условиях наблюдения. Результаты исследования показывают, что точность оценивания определяется как архитектурой нейронной сети, так и способом представления входного сигнала. Полносвязная сеть MLP показала сравнительно низкую эффективность,

тогда как сверточные нейронные сети обеспечили высокую точность для обоих рассмотренных способов формирования обучающих данных. Высокие эффективности были получены с использованием архитектуры 2D-CNN и время-частотного представления сигнала, что подтверждает ключевую роль выбора способа представления данных при решении задач оценивания параметров радиосигналов. Применение автоэнкодера для предварительного шумоподавления позволило незначительно повысить эффективность обучения, однако это сопровождалось увеличением вычислительной сложности и времени обучения. Таким образом, для рассматриваемой задачи выбор адекватного представления сигнала оказывает более существенное влияние на точность оценивания, чем использование дополнительного этапа шумоподавления.

Финансирование: Исследование выполнено за счет гранта Российского научного фонда № 24-19-00891, https://rscf.ru/project/24-19-00891/

Литература

1. Куликов Е.И., Трифонов А.П. Оценка параметров сигналов на фоне помех. – М.: Сов. радио, 1978.
2. Корчагин Ю.Э. Оценка длительности радиосигнала с неизвестными амплитудой и фазой // Радиотехника. – 2013. – №. 9. – С. 011-019.
3. Korchagin Y.E. Estimation of the radio pulse duration with unknown phase // Radioelectronics and Communications Systems. – 2013. – Т. 56. – №. 7. – С. 345-355.
4. Трифонов А.П., Шинаков Ю.С. Совместное различение сигналов и оценка их параметров на фоне помех. – М.: Радио и связь, 1986.
5. Жашкова Т.В., Ренскова А.Ю. Сравнительный анализ эффективности сверточных и рекуррентных нейронных сетей для задач идентификации сложных сигналов // Современные информационные технологии – 2025. – №. 42. – С. 127-130.

6. Zhou Y., Jiao X. Intelligent analysis system for signal processing tasks based on LSTM recurrent neural network algorithm // Neural Computing and Applications. – 2022. – Т. 34. – №. 15. – С. 12257-12269. https://doi.org/10.1007/s00521-021-06478-6
7. Jiao J. et al. An overview of wireless communication technology using deep learning // China Communications. – 2021. – Т. 18. – №. 12. – С. 1-36. https://doi.org/10.23919/JCC.2021.12.001
8. Корчагин Ю.Э., Нгуен Ван Тхю. Анализ различных нейросетевых алгоритмов для оценки амплитуды радиосигнала с неизвестными начальной фазой, длительностью и частотой // Журнал радиоэлектроники. – 2026. – №. 5. https://doi.org/10.30898/1684-1719.2026.5.15
9. Pan X., Wang Y., Qi Y. Artificial neural network model and its application in signal processing // Asian Journal of Advanced Research and Reports. – 2023. – Т. 17. – №. 1. – С. 1-8. https://doi.org/10.9734/AJARR/2023/v17i1459
10. Alkhafaji M.J.A. et al. A Lightweight 1D CNN for unified real-time communication signal classification and denoising in low-SNR edge environments // Buletin Ilmiah Sarjana Teknik Elektro. – 2025. – Т. 7. – №. 3. – С. 496-508. https://doi.org/10.12928/biste.v7i3.13789
11. Schneider N., Lermer M., Reich C. Investigating the performance of CNN feature extractor-based LSTM and GRU variants for time series classification // Procedia Computer Science. – 2024. – Т. 246. – С. 1070-1079. https://doi.org/10.1016/j.procs.2024.09.526
12. Yang T.Y. et al. A radio signal recognition approach based on complex-valued CNN and self-attention mechanism // IEEE Transactions on Cognitive Communications and Networking. – 2022. – Т. 8. – №. 3. – С. 1358-1373. https://doi.org/10.1109/TCCN.2022.3179450

Для цитирования:

Нгуен Ван Тхю, Корчагин Ю.Э. Анализ различных нейросетевых алгоритмов для оценки длительности радиосигнала с неизвестными амплитудой, частотой и начальной фазой // Журнал радиоэлектроники – 2026 – №. 10 https://doi.org/10.30898/1684-1719.2026.9.15