

DOI: <https://doi.org/10.30898/1684-1719.2026.5.15>

УДК: 621.391

АНАЛИЗ РАЗЛИЧНЫХ НЕЙРОСЕТЕВЫХ АЛГОРИТМОВ ДЛЯ ОЦЕНКИ АМПЛИТУДЫ РАДИОСИГНАЛА С НЕИЗВЕСТНЫМИ НАЧАЛЬНОЙ ФАЗОЙ, ДЛИТЕЛЬНОСТЬЮ И ЧАСТОТОЙ

Ю.Э. Корчагин, Нгуен Ван Тхю

**Воронежский государственный университет,
394006, Воронеж, пл. Университетская, д. 1**

Статья поступила в редакцию 30 апреля 2026 г.

Аннотация. В работе проведено исследование нескольких нейросетевых алгоритмов оценки амплитуды радиосигнала с огибающей произвольной формы при условии априорной неопределенности относительно длительности, начальной фазы и несущей частоты сигнала. Получена нижняя граница дисперсии оценки амплитуды, выполнено сравнение точности оценок, формируемых различными архитектурами нейронных сетей, а также осуществлено сопоставление с нижней границей Крамера-Рао. Проанализирована эффективность функционирования различных архитектур нейронных сетей при условии, что обучающие данные представлены в виде сигналов во временной области, а также в форме частотно-временных спектров. Показано, что точность нейронной сети зависит не только от ее архитектуры, но и от типа обучающих данных. Сверточные нейронные сети показывают высокую эффективность в обоих случаях: при представлении обучающих данных в дискретной форме в частотно-временной области достигаются наилучшие результаты. Напротив, полносвязные нейронные сети характеризуются низкой эффективностью для обоих типов представления

обучающих данных. Управляемый рекуррентный блок функционирует эффективно при условии, что входные данные представлены в виде дискретных значений во временной области, однако наблюдается существенное снижение эффективности оценки при использовании частотно- временных спектров в качестве формы представления обучающих данных.

Ключевые слова: радиосигнал, нейросетевой алгоритм, оценка амплитуды, сверточная нейронная сеть, многослойный перцептрон, управляемый рекуррентный блок, неизвестная частота, длительность, начальная фаза.

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

Автор для переписки: Корчагин Юрий Эдуардович, korchagin@phys.vsu.ru

Введение

Оценка амплитуды сигнала в условиях наличия шума является одной из важных задач в области обработки сигналов. Она имеет широкую сферу применения, включая мониторинг состояния механических систем, обнаружение и обработку радиолокационных сигналов, анализ биомедицинских сигналов, а также многочисленные другие технические и научные области. Так, например, оценка амплитуды и временных задержек отраженных сигналов от межсроевых границ имеет особую значимость в георадарных системах [1]. В беспроводных системах одним из наиболее распространенных методов измерения расстояния является метод, основанный на оценке уровня мощности радиосигнала, при этом точность оценки амплитуды сигнала непосредственно влияет на погрешность измерения [2]. В научной литературе было проведено значительное количество исследований, направленных на разработку статистических методов синтеза и анализа алгоритмов оценки параметров, а также на минимизацию погрешностей в процессе оценивания [3-5]. Были предложены различные способы, направленные на повышение точности и адаптацию к различным априорным условиям в процессе оценки амплитуды радиосигнала. В работе [3] исследована максимально правдоподобная (МП) оценки амплитуды детерминированного

сигнала при априори известных прочих параметрах, получены соответствующие характеристики оценки. В работе [4] синтезирован квазиправдоподобный (КП) алгоритм оценки амплитуды узкополосного радиосигнала при неизвестных длительности и начальной фазе, согласно которому вместо неизвестных длительности и начальной фазы сигнала используются их некоторые ожидаемые значения. Каждый алгоритм обладает своими преимуществами и ограничениями. МП оценка обеспечивает высокую точность, однако требует большего объема априорной информации. Применение квазиправдоподобных способов для преодоления априорной параметрической неопределенности позволяет синтезировать алгоритмы оценки, которые довольно просто реализовать технически или программно. Однако, несовпадение ожидаемых значений неизвестных параметров с их истинными значениями приводят к ухудшению эффективности оценки [4]. Нейросети не требуют большого объема априорной информации и могут быть достаточно легко реализованы, кроме того, они показывают высокую эффективность и потенциал дальнейшего развития. В связи с этим в последние годы применение искусственных нейронных сетей в области обработки сигналов становится более распространенным и активно используется во многих научных исследованиях [6-8]. Следует подчеркнуть, что задача оценки амплитуды радиосигнала может быть решена с использованием различных моделей искусственных нейронных сетей, при этом достигаемая точность существенно зависит от конкретной архитектуры и типа обучающих данных. Следовательно, анализ эффективности различных нейронных сетей для задачи оценки амплитуды сигнала в условиях априори неизвестных частоты, длительности и начальной фазы является весьма актуальной. В данной работе были выбраны три архитектуры нейронных сетей. Первая из них представляет многослойный персептрон (MLP) со структурой, включающей несколько последовательно соединенных полносвязных слоев, вторая – сверточная нейронная сеть (CNN), содержащая несколько сверточных слоев и третья – управляемый рекуррентный блок (GRU).

1. Постановка задачи

Запишем радиосигнал в виде

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

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

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

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

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

Она представляет собой аддитивную смесь полезного сигнала (1) и гауссовского белого шума $n(t)$. Здесь $a_0, \varphi_0, \omega_0, \tau_0$ – истинные значения амплитуды, начальной фазы, частоты и длительности сигнала соответственно. Белый шум $n(t)$ обладает односторонней спектральной плотностью мощности N_0 . Необходимо сформировать оценку амплитуды полезного сигнала (1), считая длительность, начальную фазу и частоту радиосигнала неизвестными параметрами, в оценке которых нет необходимости.

2. Нижняя граница Крамера-Рао

При неизвестных длительности, амплитуде, частоте и начальной фазе логарифма функционала отношения правдоподобия (ФОП) зависит от четырех неизвестных параметров:

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

Логарифм ФОП (2) представляет собой случайное поле, дифференцируемое по переменным a , φ , ω и недифференцируемое по переменной τ . Следовательно, амплитуда и начальная фаза и частота являются регулярными параметрами сигнала, а длительность – разрывным параметром [3].

Таким образом, условия регулярности частично нарушаются. В работе [9] показано, что смещение и дисперсия МП оценки амплитуды с неизвестной длительностью при больших отношениях сигнал/шум (ОСШ) асимптотически совпадают со смещением и рассеянием оценки амплитуды сигнала с априори известной длительностью. Это значит, что незнание длительности сигнала не влияет на нижнюю границу Крамера-Рао оценки амплитуды. Таким образом, для поиска нижней границы оценки амплитуды можно далее положить $\tau = \tau_0$ и найти корреляционную матрицу совместных оценок амплитуды, начальной фазы и частоты. Для этого найдем информационную матрицу Фишера

$$I = \begin{bmatrix} \left. \frac{d^2 S(a, \varphi, \omega)}{dada} \right|_{\substack{\omega=\omega_0 \\ \varphi=\varphi_0 \\ a=a_0}} & \left. \frac{d^2 S(a, \varphi, \omega)}{dad\varphi} \right|_{\substack{\omega=\omega_0 \\ \varphi=\varphi_0 \\ a=a_0}} & \left. \frac{d^2 S(a, \varphi, \omega)}{dad\omega} \right|_{\substack{\omega=\omega_0 \\ \varphi=\varphi_0 \\ a=a_0}} \\ \left. \frac{d^2 S(a, \varphi, \omega)}{d\varphi da} \right|_{\substack{\omega=\omega_0 \\ \varphi=\varphi_0 \\ a=a_0}} & \left. \frac{d^2 S(a, \varphi, \omega)}{d\varphi d\varphi} \right|_{\substack{\omega=\omega_0 \\ \varphi=\varphi_0 \\ a=a_0}} & \left. \frac{d^2 S(a, \varphi, \omega)}{d\varphi d\omega} \right|_{\substack{\omega=\omega_0 \\ \varphi=\varphi_0 \\ a=a_0}} \\ \left. \frac{d^2 S(a, \varphi, \omega)}{d\omega da} \right|_{\substack{\omega=\omega_0 \\ \varphi=\varphi_0 \\ a=a_0}} & \left. \frac{d^2 S(a, \varphi, \omega)}{d\omega d\varphi} \right|_{\substack{\omega=\omega_0 \\ \varphi=\varphi_0 \\ a=a_0}} & \left. \frac{d^2 S(a, \varphi, \omega)}{d\omega d\omega} \right|_{\substack{\omega=\omega_0 \\ \varphi=\varphi_0 \\ a=a_0}} \end{bmatrix},$$

где

$$S(a, \varphi, \omega) = \frac{aa_0}{N_0} \int_0^{\tau_0} f^2(t) \cos[(\omega - \omega_0)t - (\varphi - \varphi_0)] dt - \frac{a^2}{2N_0} \int_0^{\tau_0} f^2(t) dt \quad (3)$$

– сигнальная составляющая логарифма ФОР (2) при $\tau = \tau_0$. Вычисляя производные функции (3) и пренебрегая интегралами от функций, осциллирующих с удвоенной частотой, находим

$$I = \begin{bmatrix} q_1 & 0 & 0 \\ 0 & a_0^2 q_1 & -a_0^2 q_2 \\ 0 & -a_0^2 q_2 & a_0^2 q_3 \end{bmatrix},$$

$$\text{где } q_1 = \frac{1}{N_0} \int_0^{\tau_0} f^2(t) dt, \quad q_2 = \frac{1}{N_0} \int_0^{\tau_0} t f^2(t) dt, \quad q_3 = \frac{1}{N_0} \int_0^{\tau_0} t^2 f^2(t) dt.$$

На основе информационной матрицы Фишера получаем нижнюю границу для дисперсии оценки амплитуды с неизвестными длительностью, начальной фазой и частотой.

$$D_a = \frac{1}{q_1} = \frac{a_0^2}{z_0^2}, \quad (4)$$

где $z_0^2 = a_0^2 q_1$ – отношение ОСШ на выходе приемника МП для сигнала с амплитудой a_0 и длительностью τ_0 .

3. Нейросетевые алгоритмы оценки амплитуды радиосигнала

Применение нейросети предполагает формирование радиосигнала с неизвестными параметрами и белого шума в виде дискретных отсчетов. На интервале наблюдения $[0, T]$ располагается $N = \text{int}(Tf_s)$ 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

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

В качестве обучающих данных для различных нейронных сетей предлагаются дискретные отсчеты принятой реализации или ее спектрограммы с целью анализа влияния формы входных данных на точность нейронной сети в задаче оценки амплитуды. На рис. 1 показаны примеры различных типов входных данных




Рис. 1. Пример формы принятой реализации (сверху) и ее спектрограммы (снизу)

Выходом нейросети должно являться значения амплитуды. Следовательно, необходимо разработать соответствующую нейросеть и обеспечить достаточно большой объем обучающих данных, чтобы модель могла обучиться формировать оценку амплитуды, учитывая характеристики сигнала и шума. Общий объем обучающей выборки составлял 40000 реализаций смеси сигнала и шума. Для каждой реализации отношение ОСШ выбиралось случайным образом из диапазона значений от 0.1 до 100. Такой подход позволяет охватить различные сигнальные и помеховые условия, тем самым повышая обобщающую способность и надежность модели при определении амплитуды сигнала в широком диапазоне уровней шума. Каждой реализации ставилось в соответствие истинное значение амплитуды a_0 для организации обучения с учителем.

После обучения модели было выполнено статистическое моделирование нейросети путем расчета нормированных смещения $b = \langle \hat{a} - a_0 \rangle / a_0$ и рассеяния $v = \langle (\hat{a} - a_0)^2 \rangle / a_0^2$, где $\hat{a}$ – оценка, сформированная нейросетью. В ходе моделирования на каждом испытании с номером m формировалась входная реализация, выполнялось ее преобразование нейросетью, вычислялась оценка амплитуды $\hat{a}_m$, накапливались ошибки оценки

$$\sum_{m=1}^V (\hat{a}_m - a_0), \quad \sum_{m=1}^V (\hat{a}_m - a_0)^2$$

и вычислялись выборочные значения смещения и рассеяния

$$b = \frac{1}{Va_0} \sum_{m=1}^V (\hat{a}_m - a_0), \quad v = \frac{1}{a_0^2 V} \sum_{m=1}^V (\hat{a}_m - a_0)^2.$$

Всего было реализовано $V = 10^6$ циклов испытаний. Амплитуда сигнала выбиралась случайным образом из равномерного распределения в диапазоне от 0.1 до 10.

3.1. Многослойный персептрон

Первая нейронная модель, рассматриваемая в данной работе – это многослойный персептрон (MPL). Несмотря на то что архитектура MLP не является специализированной и оптимальной для задач, в которых входные векторы обладают временной структурой и характеризуются сложными статистическими зависимостями, ее изучение и оценка сохраняют очевидную научную значимость. Для устранения данного ограничения предлагается глубокая модель MLP, организованная в виде последовательной архитектуры, с целью повышения способности извлечения и обучения признаков, связанных с амплитудой, на основе обучающих данных.

а. Многослойный персептрон с анализом принятой реализации

На рис. 2 показан блок-схема MLP с анализом принятой реализацией




Рис. 2. Блок-схема нейросети многослойного персептрона.

Нейронная сеть была реализована с использованием архитектуры Sequential библиотеки Keras для обработки данных в виде векторов. Модель состоит из четырех блоков полносвязных слоев (Dense), каждый из которых включает два слоя Dense, за которыми следует слой Dropout. Последний слой Dense прогнозирует амплитудное значение сигнала. Всего модель содержит девять полносвязных слоев. Обучение проводилось с использованием оптимизатора Adam и при функции потерь средний квадрат ошибки (MSE). Здесь обозначено: Dense 1 и Dense 2 полносвязные слои, каждый из которых содержит 128 нейронов и отвечает за извлечение ключевых признаков из входных данных.

Далее слои Dense 3 и Dense 4 включают по 64 нейрона, Dense 5 и Dense 6 содержат 32 нейрона, а Dense 7 и Dense 8 – 16 нейронов в каждом слое. Последний слой Dense 9 состоит из одного нейрона с линейной функцией активации, который выдает значение амплитуды сигнала. В качестве функций активации всех слоев, кроме последнего, использовалась встроенная в библиотеку TensorFlow функция ReLU. Для снижения эффекта переобучения используется метод Dropout с коэффициентом 0.1, при котором случайным образом деактивируется небольшая часть нейронов в процессе обучения, что способствует повышению обобщающей способности модели. Кроме того, применяется стратегия ранней остановки (Early Stopping) для оптимизации процесса обучения и предотвращения переобучения. В частности, обучение контролируется по значению функции потерь на валидационной выборке; при отсутствии улучшения в течение 10 последовательных эпох процесс обучения останавливается, а модель восстанавливается к состоянию с наилучшими достигнутыми весами.

6. Многослойный персептрон с анализом спектрограммы

Для наглядного сравнения влияния формы обучающих данных на точность нейросетевой оценки амплитуды воспользуемся сетью MLP, использующей в качестве входных данных спектрограммы. Сохраним те же параметры и количество полносвязных слоев, что и на рисунке 2. Однако, поскольку спектрограмма представляет собой двумерные данные, перед подачей на полносвязные слои необходимо использовать слой Flatten для преобразования данных в одномерный вектор, что обеспечивает соответствие требованиям входа для Dense-слоев. Длина каждого подотрезка сигнала, используемого для спектральной оценки, задается параметром $n_{perseg} = 128$, что обеспечивает баланс между временным и частотным разрешением. Параметр $n_{overlap} = n_{perseg}/2$ определяет 50 %-ное перекрытие между последовательными окнами, что повышает гладкость оценки и снижает дисперсию спектральной

оценки. Наконец, $nfft = 256$ задает число точек быстрого преобразования Фурье, используемых для каждого сегмента.

3.2. Сверточные нейронные сети

Сверточная нейросеть широко используется и многократно применялась в различных задачах, демонстрируя высокую эффективность, особенно для данных, обладающих пространственной и временной структурой [10-12]. Сигнал имеет структуру во временной области, в которой такие характеристики, как амплитуда, частота и начальная фаза, представляют собой признаки, эффективно извлекаемые сверточными нейронными сетями. Выполним синтез и анализ двух моделей – одномерная сверточная нейросеть (CNN1D) и двумерная сверточная нейросеть (CNN2D) соответствующих двум типам входных данных: дискретным значениям во временной области и частотному спектру.

а. Одномерная сверточная нейросеть с анализом принятой реализации

На рис. 3 изображена блок- схема CNN1D для задачи оценки амплитуды




Рис. 3. Блок – схема одномерной сверточной нейросети.

Модель реализована в виде Sequential структуры, обеспечивающей линейную организацию слоев. Первый слой представляет собой одномерный сверточный слой с 16 фильтрами и размером ядра 9 и использует функцию активации ReLU в сочетании с режимом дополнения «same», что позволяет сохранять длину входной последовательности. Далее применяется слой максимального объединения MaxPooling1D с размером окна 3 для уменьшения размерности и повышения устойчивости к шуму. Данная архитектура

повторяется трижды с увеличением числа фильтров 16, 32 и 64, что позволяет модели обучаться иерархическим признакам – от локальных к более абстрактным представлениям в последовательности данных. После сверточных и объединяющих слоев выходные данные преобразуются в одномерный вектор с помощью слоя Flatten. Затем следуют два полносвязных слоя с 64 и 32 скрытыми нейронами соответственно, использующими функцию активации ReLU для обучения нелинейным представлениям извлеченных признаков. Для снижения эффекта переобучения после каждого полносвязного слоя применяется метод Dropout с коэффициентом 0.1, что способствует улучшению обобщающей способности модели. Выходной слой состоит из одного нейрона с линейной функцией активации, что соответствует задачам регрессии, в которых требуется предсказание непрерывного значения. В части конфигурации обучения используется оптимизатор Adam – широко применяемый адаптивный алгоритм оптимизации в задачах глубокого обучения. В качестве функции потерь выбрана функция MSE. Наконец, для предотвращения переобучения применяется стратегия ранней остановки. В частности, процесс обучения контролируется по значению функции потерь на валидационной выборке; при отсутствии улучшения в течение 10 последовательных эпох обучение прекращается, а модель восстанавливается в состоянии с наилучшими весами, достигнутыми в ходе обучения.

б. Одномерная сверточная нейросеть с анализом спектрограммы

Архитектура двумерной сверточной нейронной сети построена аналогично представленной на рис. 3, при этом сохраняются количество сверточных слоев и число фильтров в каждом слое для обеспечения согласованности, что позволяет провести наглядное сравнение эффективности двумерной и одномерной сверточных сетей в задаче оценки амплитуды радиосигнала. Ввиду различий в формате обучающих данных одномерные сверточные слои, представленные на рис. 2, заменяются двумерными сверточными слоями с размером ядра 3×3 . Далее применяется слой максимального объединения (MaxPooling2D) с размером окна

2×2 , что позволяет уменьшить размерность признаков при сохранении наиболее значимой информации сигнала.

3.3. Управляемый рекуррентный блок

Управляемый рекуррентный блок широко применяется в задачах обработки последовательных данных, таких как текст и временные сигналы, благодаря своей способности эффективно моделировать временные зависимости [13-14]. В частности, GRU использует механизм вентилей, включающий обновляющий вентиль и сбрасывающий вентиль, что позволяет модели гибко регулировать сохранение или удаление информации из предыдущих временных шагов. Благодаря этому GRU способен одновременно учитывать как краткосрочные, так и долгосрочные зависимости в последовательных данных. Кроме того, GRU помогает преодолеть проблему затухающего градиента, характерную для традиционных рекуррентных нейронных сетей, что улучшает способность обучения на длинных последовательностях. Именно поэтому GRU часто используется в задачах обработки естественного языка и анализа временных сигналов, особенно в случаях, требующих баланса между точностью и вычислительными затратами. В данной работе предлагается использовать двунаправленную сеть GRU (BiGRU) для одновременного извлечения информации в обоих временных направлениях входных данных, что позволяет повысить способность модели к представлению признаков сигнала. BiGRU включает два параллельных потока обработки: один обрабатывает последовательность в прямом временном направлении, а другой – в обратном. Объединение информации из обоих направлений позволяет формировать более информативные контекстные представления на каждом временном шаге, что особенно полезно при распознавании сложных сигнальных паттернов, аномальных колебаний или периодических структур.

а. Управляемый рекуррентный блок с анализом принятой реализации

На рис. 4 изображена блок-схема управляемого рекуррентного блока для задачи оценки амплитуды радиосигнала.




Рис. 4. Блок – схема управляемого рекуррентного блока.

Предлагаемая в данной работе модель построена в виде рекуррентной нейронной сети архитектуры Sequential, в которой используются два двунаправленных слоя BiGRU для полного извлечения контекстной информации из последовательности входных данных в обоих временных направлениях.

В частности, первый слой BiGRU содержит 64 скрытых нейрона и настроен с параметром `return_sequences = True`, что позволяет передавать всю последовательность признаков на следующий слой, обеспечивая тем самым обучение как краткосрочных, так и среднесрочных зависимостей в последовательных данных. Далее применяется слой Dropout с коэффициентом 0.1, предназначенный для уменьшения переобучения за счет случайного отключения части связей в процессе обучения. Затем второй слой BiGRU с 32 скрытыми нейронами используется для извлечения более высокоуровневых представлений из уже закодированной последовательности, после чего также применяется второй слой Dropout с тем же коэффициентом 0.1. Последующая часть сети включает полносвязный слой Dense с 16 нейронами и функцией активации ReLU, предназначенный для моделирования нелинейных зависимостей в пространстве извлеченных признаков. Выходной слой представляет собой Dense-слой с одним нейроном и линейной функцией активации, что соответствует задаче регрессии с непрерывным выходом. Обучение модели осуществляется с использованием оптимизатора Adam, при

функции потерь MSE. Для повышения обобщающей способности и предотвращения переобучения применяется механизм ранней остановки, основанный на мониторинге значения функции потерь на валидационной выборке, с параметром $\text{patience} = 10$ и восстановлением лучших весов модели, достигнутых в процессе обучения.

6. Управляемый рекуррентный блок с анализом спектрограммы

Далее рассмотрим модель GRU, в которой в качестве обучающих данных используются спектрограммы принятой реализации. Модель разработана для обработки спектрально-временных данных посредством нормализации входных данных и преобразования их в последовательную структуру, подходящую для двунаправленной рекуррентной сети. Архитектура BiGRU построена аналогично модели, представленной на рис. 4, при этом сохраняется глубина сети и количество нейронов в каждом слое, что позволяет провести наглядное сравнение эффективности различных сетевых архитектур в задаче оценки амплитуды радиосигнала. Перед подачей в BiGRU данные преобразуются в последовательный двухмерный формат с помощью слоя Reshape в библиотеке Keras, где каждому временному шагу соответствует вектор признаков, а вся спектральная информация в каждый момент времени агрегируется в единый вектор признаков.

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 . 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 $x_0 = \tau_0 / T_2$, $\tau_0 = \frac{T_1 + T_2}{2}$. Введем величину $\eta = \Delta\omega T_2 / 2\pi = \delta\omega\kappa$, которую назовем обобщенной нестабильностью несущей частоты. Здесь обозначено $\delta\omega = \Delta\omega / \omega_0$ – относительная нестабильность несущей частоты, $\kappa = \omega_0 T_2 / 2\pi$ – число периодов колебания в импульсе максимально возможной длительности.




Рис. 5. Зависимость условного смещения от ОСШ.




Рис. 6. Зависимость условного рассеяния от ОСШ.

Величина k характеризует ширину полосы частот радиосигнала и может быть аналогично названа параметром узкополосности. При обучении нейросетей и моделировании параметр узкополосности выбирался случайно из диапазона $k \in [1, 100]$. На рис. 5 и 6 показаны зависимости условных смещения и рассеяния от ОСШ для динамического диапазона $k = 4$ и $b = -0.35$.

Ромбиками представлены результаты статистического моделирования оценки амплитуды при использовании модели многослойного персептрона, треугольниками – модели BiGRU, кружками – сверточной нейронной сети. Закрашенные маркеры соответствуют результатам оценки амплитуды нейросетями при анализе принятой реализации, незакрашенные – при анализе спектрограммы. На рис. 6 сплошная кривая соответствует нижней границе Крамера–Рао (4) в задаче оценки амплитуды. Из рис. 5 и 6 следует, что исследованные в данной работе модели на текущий момент не достигают нижней границы Крамера–Рао. Полносвязная нейронная сеть показывает ограниченную эффективность для обоих типов обучающих данных – как в виде принятой реализации, так и в виде спектрограммы. Это указывает на ее ограниченную пригодность для задач оценки параметров сигнала. В то же время сверточные нейронные сети показывают существенно более высокую эффективность в обоих случаях обучающих данных, при этом двумерная сверточная сеть с входными данными в виде спектрограмм обеспечивает наилучшие результаты среди проанализированных моделей. Модель BiGRU также обладает высокой эффективностью и дает результаты, сопоставимые с двумерной сверточной сетью при использовании обучающих данных в виде принятой реализации. Однако ее точность существенно снижается при применении к обучающим данным в виде спектрограмм. Кроме того, можно наблюдать выраженное влияние обучающих данных на точность нейронных моделей. Выбор и оптимизация обучающих данных, а также архитектуры нейронной сети в задаче оценки амплитуды играют ключевую роль в снижении ошибки модели.

Заключение

Нейросетевые алгоритмы оценки амплитуды уступают статистически оптимальным методам. Их использование оправдано в случаях, когда построение оптимальных устройств невозможно из-за недостаточности априорной информации. Эффективность модели в значительной степени определяется архитектурой нейронной сети и характеристиками обучающих данных. Каждая архитектура достигает наилучших показателей при обучении на соответствующем типе данных. Экспериментальные результаты показывают, что полносвязная нейронная сеть изображает низкую эффективность, а сверточные нейронные сети показывают высокую эффективность для обоих предложенных типов обучающих данных, при этом двумерная сверточная нейросеть с входными данными в виде частотно-временного представления обеспечивает наилучшие результаты среди рассмотренных моделей. В то же время сеть GRU обеспечивает показатели, сопоставимые с CNN2D при использовании обучающих данных в виде дискретных отсчетов принятой реализации. Это улучшение отражает преимущество моделей, обладающих способностью к извлечению и сохранению временной структуры сигнала, что повышает точности оценивания.

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

Литература

1. Zheng S. et al. Estimation of echo amplitude and time delay for OFDM-based ground-penetrating radar // IEEE Geoscience and Remote Sensing Letters. – 2015. – Т. 12. – №. 12. – С. 2384-2388. <https://doi.org/10.1109/LGRS.2015.2478279>
2. Zanella A. Best practice in RSS measurements and ranging // IEEE Communications Surveys and Tutorials. – 2017. – Т. 18. – №. 4. – С. 2662-2686. <https://doi.org/10.1109/COMST.2016.2553452>
3. Куликов Е.И., Трифонов А.П. Оценка параметров сигналов на фоне помех. – М.: Сов. радио, 1978. – 296 с.
4. Трифонов А.П. и др. Оценка амплитуды прямоугольного узкополосного радиоимпульса с неизвестными длительностью и начальной фазой // Известия высших учебных заведений Радиоэлектроника. – 2017. – Т. 60. – №. 12. – С. 675-684. <https://doi.org/10.20535/S0021347017120019>
5. Трифонов А.П., Шинаков Ю.С. Совместное различение сигналов и оценка их параметров на фоне помех. – М.: Радио и связь, 1986. – 268 с.
6. Jwo D.J., Biswal A., Mir I.A. Artificial neural networks for navigation systems: A review of recent research // Applied Sciences. – 2023. – Т. 13. – №. 7. – С. 4475. <https://doi.org/10.3390/app13074475>
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. Андреев В.В., Славутский Л.А., Славутская Е.В. Обработка сигналов нейросетью прямого распространения: аппроксимация и принятие решений // Вестник Чувашского университета. – 2022. – №. 1. – С. 14-22. <https://doi.org/10.47026/1810-1909-2022-1-14-22>
9. Трифонов А.П., Бутейко В.К. Характеристики совместных оценок параметров сигнала при частичном нарушении условий регулярности // Радиотехника и электроника. – 1991. – Т. 36. – №. 2. – С. 319-327.

10. Мельник Э.В. и др. Проектирование модулей нейросетей MLP и CNN на ПЛИС для задач классификации изображений // Известия Южного федерального университета. Технические науки. – 2025. – №. 5 (247). – С. 214-229.
11. Li Y., Xie T., Mei D. Application of convolutional neural networks for parallel multi-scale feature extraction in noise image denoising // IEEE Access. – 2024. – Т. 12. – С. 98599-98610. <https://doi.org/10.1109/ACCESS.2024.3427143>
12. Zhanga J., Zhangb X., Jic X. Application of Convolutional Neural Networks in High Score Remote Sensing Image Classification // Academic Journal of Computing & Information Science. – 2024. – Т. 7. – №. 2. – С. 79-84. <https://doi.org/10.25236/AJCIS.2024.070211>
13. 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>
14. Yang T.Y. et al. GNSS–VTEC prediction based on CNN–GRU neural network model during high solar activities // Scientific reports. – 2025. – Т. 15. – №. 1. – С. 9109. <https://doi.org/10.1038/s41598-025-93628-8>

Для цитирования:

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>