



Научная статья

УДК 621.396; 621.395.742

URL: <https://trudymai.ru/published.php?ID=189162>

EDN: <https://www.elibrary.ru/YSFOIK>

МЕТОДИКА ОЦЕНКИ ИНТЕРВАЛОВ ЦИКЛОСТАЦИОНАРНОСТИ ВЕРОЯТНОСТНОЙ КОМПОНЕНТЫ ДИНАМИЧЕСКИХ РИСКОВ ВОЗДУШНЫХ СЕТЕЙ СВЯЗИ НА ОСНОВЕ КОМБИНАЦИИ SCD-АНАЛИЗА и LSTM-КОРРЕКЦИИ

А.В. Ананьев^{1,2}, В.А. Печкарев^{2✉}, С.И. Моисеев³

¹Федеральное государственное бюджетное образовательное учреждение высшего образования «Российский экономический университет имени Г.В. Плеханова,
г. Воронеж, Россия

²Федеральное государственное казенное военное образовательное учреждение высшего профессионального образования «Военный учебно-научный центр Военно-воздушных сил «Военно-воздушная академия имени профессора Н.Е. Жуковского и Ю.А. Гагарина» Министерства обороны Российской Федерации, г. Воронеж, Россия

³Федеральное государственное бюджетное образовательное учреждение высшего образования «Воронежский государственный технический университет»,
г. Воронеж, Россия

✉ val.pechkarev_0658@mail.ru

Цитирование: Ананьев А.В., Печкарев В.А., Моисеев С.И. Методика оценки интервалов циклоstationарности вероятностной компоненты динамических рисков воздушных сетей связи на основе комбинации SCD-анализа и LSTM-коррекции // Труды МАИ: электрон. журнал. № 149. URL: <https://trudymai.ru/published.php?ID=189162>

Аннотация. В статье предложена методика для дискретной оценки рисков, основанная на гибридном методе оценки интервалов циклоstationарности. Методика отличается от известных подходов комбинацией спектрального корреляционного анализа (SCD) и легковесной рекуррентной нейронной сети с долговременной краткосрочной памятью (LSTM). Методика позволяет обосновать требования к системе связи в части касающейся решения проблемы неstationарности сигналов, заключающейся в динамичности изменяющейся среды, характерной для воздушных сетей связи. В предложенной методике

SCD-анализ обеспечивает первичную оценку циклостационарных свойств сигналов, а LSTM модель адаптивно корректирует интервалы с учетом изменений параметров сети. В предложенной методике гибридного SCD-LSTM подхода одним из ключевых аспектов является адаптация нейросетевой модели к высокой динамике изменений в воздушных сетях связи.

Ключевые слова: воздушные сети связи; динамические риски; циклостационарность; статистическая выборка; оценка риска.

METHODOLOGY FOR ESTIMATING CYCLOSTATIONARITY INTERVALS OF THE PROBABILISTIC COMPONENT OF DYNAMIC RISKS IN AERIAL COMMUNICATION NETWORKS USING COMBINED SCD-ANALYSIS AND LSTM-CORRECTION

A.V. Ananjev^{1,2}, V.A. Pechkarev²✉, S.I. Moiseev³

¹ Federal State-Funded Educational Institution of Higher Professional Education «Plekhanov Russian University of Economics», Voronezh, Russia

² Federal State Official Military Educational Institution of Higher Professional Education Military Educational-Research Centre of Air Force «Air Force Academy named after professor N.E. Zhukovsky and Y.A. Gagarin»

of the Ministry of Defence of the Russian Federation, Voronezh, Russia

³ Federal State-Funded Educational Institution of Higher Professional Education «Voronezh state technical university», Voronezh, Russia

✉ val.pechkarev_0658@mail.ru

Citation: Ananjev A.V., Pechkarev V.A., Moiseev S.I. Methodology for estimating cyclostationarity intervals of the probabilistic component of dynamic risks in aerial communication networks using combined SCD-analysis and LSTM-correction // Trudy MAI. 2026. No. 149. (In Russ.). URL: <https://trudymai.ru/published.php?ID=189162>

Abstract. The paper proposes a methodology for the discrete risk assessment based on a hybrid method for estimating cyclostationarity intervals. The methodology differs from existing approaches by combining spectral correlation analysis (SCD) with a lightweight recurrent neural network featuring long short-term memory (LSTM). The methodology enables justification of the requirements for the communication system with respect to addressing the problem of signal non-stationarity, which stems from

the dynamic nature of the changing environment typical of airborne communication networks. In the proposed methodology, SCD analysis provides an initial assessment of the signals' cyclostationary properties, while the LSTM model adaptively adjusts the intervals taking into account changes in network parameters. A key aspect of the proposed hybrid SCD-LSTM approach is the adaptation of the neural network model to the high dynamics of changes in airborne communication networks.

Keywords: overhead communication networks; dynamic risks; cyclostationarity; statistical sampling; risk assessment.

Введение

Воздушные сети связи (ВСС) представляют собой распределенную коммуникационную систему, использующую летательные аппараты (беспилотные, пилотируемые или аэростаты) в качестве узлов связи для обеспечения гибкого и мобильного покрытия в условиях отсутствия стационарной инфраструктуры или ее недостаточности. ВСС по отношению к другим сетям связи имеют следующие преимущества [2]:

- возможность предоставления услуг связи при затруднении (невозможности) применения наземных средств связи в условиях труднопроходимой (заболоченной, горной) местности, в условиях Крайнего Севера;
- оперативное устранение «мертвых зон» связи наземных эшелонов (мобильного и стационарного) в случае уничтожения (информационного блокирования) их компонентов.

В то же время, применение ВСС неотъемлемо связано с высокой динамикой изменения условий функционирования. Это прежде всего связано с движением летательных аппаратов. Высокая динамика изменения условий применения ВСС может приводить к масштабным негативным последствиям, заключающимся в полном разрушении ВСС, т.е. стремительном прекращении функционирования. В этом случае учесть масштабные разрушения, а в перспективе парировать такие явления позволяет теория рисков [4].

Согласно Большой российской энциклопедии, риск – это возможная опасность, угроза, вероятность неблагоприятного или неожиданного (в том числе положительного) результата действий или развития событий [3].

В связи с изложенными особенностями функционирования ВСС, ключевой

задачей адаптации теории рисков к данной предметной области заключается в учете высокой динамики изменения условий функционирования ВСС. Вариантом учета риска в динамике является дискретная оценка риска.

В работе [4] риск представлен в виде:

$$R_{ij} = p_{ij} \cdot C_i, \quad (1)$$

где p_{ij} – вероятность непередачи информации (отсутствия связи) от i -го узла к j -му, C_i – коэффициент признака потерь при передаче информации.

В выражении (1) достоверность коэффициента C_i определяется временем поступления данных о месторасположении источника ДФ, что будет рассмотрено дополнительно.

В настоящей работе основное внимание уделено вероятности непередачи информации p_{ij} от i -го узла к j -му. Условимся, что для оценки значений p_{ij} используются нейронные сети. В этом случае актуальность измеренного значения p_{ij} зависит, в том числе, от объема обучающей выборки, что в свою очередь может быть связано с дискретизацией оценки по времени с использованием математического аппарата циклостационарности [5].

Таким образом, данная работа посвящена разработке методики оценки циклостационарности вероятностной компоненты динамических рисков при передаче информации в воздушных сетях связи.

В качестве параметра, характеризующего динамическое изменение вероятностной компоненты рисков, примем время t .

Под вероятностной компонентой динамических рисков $p(t)$ будем понимать вероятность возникновения определенных негативных событий в сети. Например, потеря связи, задержка передачи данных, вероятность битовой ошибки, вероятность пакетной ошибки и др.

Методы оценки циклостационарности вероятностной компоненты рисков в воздушных сетях связи

Оценка вероятностной компоненты рисков $p(t)$ может осуществляться на основе циклостационарности, представляющей собой случайный процесс, статистические характеристики которого периодически изменяются во времени.

Для вероятностной функции $p(t)$ это означает, что ее математическое ожидание, дисперсия и автокорреляционная функция повторяются с некоторым периодом T :

$$m_x(t) = m_x(t + T), \quad (2)$$

где $m_x(t)$ – математическое ожидание показателя вероятностной функции.

В результате анализа работы [10] различают два типа циклостационарности: первого и второго порядка. Циклостационарность первого порядка включает периодическое повторение вероятностной компоненты динамических рисков, при этом, математическое ожидание является периодической функцией времени, описываемой выражением (2). Циклостационарность второго порядка проявляется в случае, если периодической функцией оказывается двумерная корреляционная функция вероятностной компоненты динамических рисков, которая зависит от текущего момента времени t и расстояния между моментами наблюдения τ , и является периодической функцией текущего времени:

$$K_x(t, \tau) = K_x(t + T, \tau). \quad (3)$$

Для оценки циклостационарности в сетях связи используют методы скользящей АКФ, Уэлча, SCD-анализ, Вейвлет-анализ, LSTM, однако в воздушных сетях связи применимость данных методов имеет особенности, представленные в таблице 1.

Таблица 1

Таблица применимости методов циклостационарности для оценки вероятностной компоненты рисков при передаче информации в воздушных сетях связи

Метод	Данные, которые можно получить при применении метода	Использование полученных данных для оценки p_{ij}	Особенности для воздушных сетей связи
Скользящая АКФ	Обнаружение периодических помех, оценка уровня шума	Оценка влияния периодических помех на качество связи, вероятность потери пакетов	Метод ограничен сложностью учета динамического изменения условий распространения сигнала в воздушной среде и лучше подходит для стационарных или медленно меняющихся процессов
Метод Уэлча	Оценка спектральной плотности мощности сигнала	Статистика распределения источников помех, функциональных параметров сигнала узлов сети	Метод предполагает стационарность сигнала в промежутках времени, что не используется при оценке сигналов в ВСС. Точность оценки зависит от объема статистической выборки
SCD-анализ	Выявление специфических дефектов в оборудовании	Оценка вероятности отказа аппаратуры узлов сети связи	Метод позволяет выявить периодические компоненты в сигналах, связанных с рисками. Определяет частотные характеристики циклостационарности
Вейвлет-анализ	Обнаружение кратковременных аномалий в сигналах	Оценка вероятности возникновения кратковременных аномалий	Вероятностные оценки могут быть слишком общие и не учитывать специфические особенности ВСС

Анализ источников [6–23] показывает, что подходы к оценке циклостационарности в беспроводных сетях, активно развиваются. В работах [8–10] циклостационарность используется для улучшения помехоустойчивости и качества связи. Основополагающими работами по циклостационарности в радиосигналах и обработке данных являются [11, 12]. Основным методом оценки циклостационарности в работе [15] является использование классического спектрального анализа для выявления циклостационарности в сетях 5G с БПЛА, однако он не адаптируется к изменениям отношения сигнал/шум, зависит от стационарности сигнала, и рассматривается только для стабильных сигналов. В работе [16] применяется длинная цепь элементов краткосрочной памяти для анализа сигналов БПЛА без учета циклостационарности. Основным преимуществом такого метода является возможность работы с большим объемом данных, снижение ошибки проведения расчетов путем машинного обучения. Однако в представленной работе не рассматриваются применение LSTM для оценки циклостационарности сетей связи.

Ввиду недостатков и особенностей, указанных в рассмотренных работах, разработаем методику оценки циклостационарности $p(t)$ на основе гибридного подхода, сочетающего классический метод оценки циклостационарности (SCD-анализ) [15] и коррекцию результатов расчетов значений циклостационарности путем применения LSTM модели [16]. В методике, спектральный корреляционный анализ необходим для первичной оценки циклостационарности, а LSTM модель, используется для коррекции интервалов, что принципиально отличается от существующих методов: от классического SCD-анализа [14] – возможностью динамической адаптации к изменяющимся параметрам сети, а от нейросетевых подходов [15] – сохранением физической интерпретируемости за счет базовой SCD-оценки.

Методика оценки интервалов циклостационарности вероятностной компоненты динамических рисков воздушных сетей связи на основе гибридного SCD-LSTM подхода

Опишем математическую постановку задачи. Пусть вероятностная компонента динамических рисков воздушных сетей связи описывается

случайным процессом, обладающим свойствами **циклостационарности первого порядка** с неизвестным периодом T . Требуется оценить интервал T , на котором статистические характеристики $p(t)$ (математическое ожидание, дисперсия, автокорреляционная функция) остаются периодически стабильными, на основе ограниченной выборки данных $\{p(t_i)\}, i=1 \dots N$.

Циклостационарность $p(t)$ определяется по выражениям (2, 3). Предлагаемая методика включает два этапа:

1. Спектральный корреляционный анализ для первичной оценки T_{SCD} .

Спектральная корреляционная плотность процесса $p(t_i)$ определяется по формуле:

$$S_p^\alpha(f) = F(R_p^\alpha(\tau)), R_p^\alpha(\tau) = \left\langle p(t + \tau/2) p^*(t - \tau/2) e^{(-i2\alpha\tau t)} \right\rangle_t, \quad (4)$$

Где $\langle \dots \rangle_t$ – оператор усреднения по времени t , обозначающий среднее значение выражения внутри скобок за определенный временной интервал, $\alpha = k/T$ – циклочастоты, F – преобразование Фурье, $R_p^\alpha(\tau)$ – циклическая автокорреляционная функция.

Спектральная корреляционная плотность $S_p^\alpha(f)$ вычисляется как преобразование Фурье циклической автокорреляционной функции $R_p^\alpha(\tau)$, которая усредняется по времени t для фиксированного сдвига τ .

Оценка периода T_{SCD} определяется выражением:

$$T_{SCD} = \frac{1}{\alpha_{\max}}, \alpha_{\max} = \arg \max_{\alpha} \sum_f S_p^\alpha(f). \quad (5)$$

2. LSTM модель. Для адаптации к изменяющимся условиям вводится легковесная LSTM модель, предсказывающая поправку ΔT . Она позволяет учесть динамику изменения вероятностной компоненты рисков через обучаемость LSTM ввиду того, что LSTM-сети обладают свойством запоминать долгосрочные зависимости во временных рядах.

Представим нейросетевую коррекцию значений циклостационарности в виде легковесной LSTM модели, которая предсказывает поправку ΔT к оценке T_{SCD}

, полученной SCD-анализом:

$$T = T_{SCD} + \Delta T, \Delta T = LSTM(\{p(t_i)\}, \theta), \quad (6)$$

Где θ – параметры сети, обученные минимизировать ошибку $\|T_{ucm} - T\|^2 = \sum_{i=1}^n (T_{ucmi} - T_i)^2$ на статистических данных, LSTM – тип рекуррентной нейросети, способной анализировать временные последовательности. Для задачи коррекции ΔT используется следующая структура:

входной слой, который принимает последовательность значений вероятностной компоненты рисков $\{p(t_i)\}$ за последние N временных шагов;

скрытые слои LSTM, которые обрабатывают временные зависимости с помощью механизмов.

Рассмотрим механизмы LSTM модели. Забывающий гейт, определяемый по формуле:

$$f_t = \sigma(W_f [h_{t-1}, \{p(t_i)\}] + b_f), \quad (7)$$

где W_f – матрица весов забывающего гейта, b_f – вектор весов забывающего гейта,

h_t – кратковременная память сети, которая обновляется на каждом шаге t . Формула (7) определяет, какая информация из предыдущего состояния C_{t-1} должна быть сохранена или забыта.

Входной гейт:

$$I_t = \sigma(W_i [h_{t-1}, \{p(t_i)\}] + b_i), \quad (8)$$

где W_i – матрица весов входного гейта, b_i – вектор весов входного гейта. Формула (8) решает, какие новые значения будут обновлены в состояние ячейки.

Гейт обновления состояния LSTM (долговременная память сети):

$$C_i = \tanh(W_c [h_{t-1}, \{p(t_i)\}] + b_{ci}), \quad (9)$$

где W_c – матрица весов для кандидата в новое состояние, b_c – вектор смещения для кандидата в новое состояние. Формула (9) создает вектор-кандидат для обновления состояния ячейки.

Выходной гейт определяет какая часть обновленного состояния ячейки C_i будет передана в скрытое состояние (краткосрочную память) h_t :

$$O_i = \sigma(W_o [h_{t-1}, \{p(t_i)\}] + b_{oi}), \quad (10)$$

где W_o – матрица весов входного гейта, b_o – вектор весов входного гейта. Формула 10 представляет собой линейный слой с активацией, предсказывающий поправку ΔT .

Функция потерь, определяемая по формуле:

$$L(\theta) = \sum_{j=1}^M (T_j - (T_{SCD} + \Delta T_j))^2 + \lambda \|\theta\|^2, \quad (11)$$

где λ – коэффициент регуляции, M – число примеров в обучающей выборке (эволюций), $\|\theta\|^2$ – это L_2 , характеризующую норму параметров модели (евклидова норма). Функция потерь оценивает ошибку предсказания модели MSE и осуществляет контроль переобучения за счет параметра $\lambda \|\theta\|^2$.

Каждый параметр LSTM ($W_f, W_i, W_c, W_o, b_f, b_i, b_c, b_o$) обучается для управления потоком информации (обновление), минимизации ошибки предсказания ΔT через MSE-функцию потерь, сохранения интерпретируемости за счет связи с SCD-анализом.

В итоге, суть гибридного подхода заключается в том, что SCD-анализ выявляет базовый период T_{SCD} , а LSTM корректирует его на основе динамики параметров сети. Например, если SNR падает ниже 15дБ, ΔT увеличивается, что позволяет учитывать деструктивные воздействия. Либо при росте потери пакетов $>1\%$ LSTM уменьшает T для более частого обновления статистики. Выходным параметром представленной методики является интервал T .

Для демонстрации работы методики рассмотрим воздушную сеть связи на базе беспилотных летательных аппаратов, работающую в условиях городской среды. Для проведения расчетов используем данные производительности связи в сетях с БПЛА, взятые из открытой площадки по Data Science и машинному обучению «Kaggle» [25].

Схема выполнения методики представлена на рисунке 1.




Рисунок 1 – Схема предложенной методики оценки циклостационарности

В качестве вероятностной компоненты динамических рисков $p(t_i)$ выбрана вероятность потери пакетов данных, измеренную с интервалом в 1 минуту в течение 24 часов (1440 точек). Данные содержат периодические помехи от городской инфраструктуры (например, радары с периодом $T_1=15$ мин); изменения положения БПЛА ($T_2=30$ мин); случайные шумы (SNR варьируется от 10 до 20 дБ).

На рисунке 2 представлен график вероятности потери пакетов в воздушной сети связи в зависимости от времени (в минутах). Данные охватывают 100 минут работы сети. Характерные колебания вероятности свидетельствуют о наличии периодических помех и динамических изменений в сети. График демонстрирует нестационарность сигнала.




Рисунок 2 – Исходные данные для проведения расчетов

Шаг 1 Проведение SCD-анализа.

1.1. Выполним расчет циклической корреляционной функции $R_p^\alpha(\tau)$ для $\tau \in [0, 60]$ мин. по формуле 6.

1.2. Вычислим спектральную корреляционную плотность $S_p^\alpha(f)$ и результаты расчетов представим на рисунке 3.



Рисунок 3 – График спектральной корреляционной плотности для примера

В результате проведения спектрального корреляционного анализа выявлено две доминирующие циклочастоты:

основная компонента: циклочастота $\alpha_1 = 1/15$ мин⁻¹, соответствующий период: $T_1 = 15$ мин, обусловлена периодическими помехами городской инфраструктуры;

вторичная компонента: циклочастота $\alpha_2 = 1/30$ мин⁻¹, соответствующий период: $T_2 = 30$ мин, связана с динамикой изменения положения БПЛА.

1.3. Определим доминирующие циклочастоты. Для этого построим рисунок 4, отображающий вероятность потери пакетов с наложенными интервалами циклостационарности, полученными с помощью SCD-анализа. Красные пунктирные вертикальные линии соответствуют фиксированному интервалу $T_{SCD} = 15$ минут, выявленному спектральным корреляционным анализом.



Рисунок 4 – График доминирующих циклочастот

Из рисунка 3 видно, что наибольшая энергия спектра соответствует $\alpha_1 = 1/15 \text{ мин}^{-1}$ и $\alpha_2 = 1/30 \text{ мин}^{-1}$.

Первичная оценка периода:

$$T_{SCD} = \frac{1}{\alpha_{\max}} = 15 \text{ мин} . \quad (12)$$

SCD-анализ позволил выявить базовый период циклостационарности, однако фиксированные интервалы не учитывают динамические изменения параметров сети. Это подчеркивает необходимость коррекции интервалов с помощью LSTM.

Шаг 2. Корректировка значения периода T_{SCD} путем применения LSTM модели.

2.1 Установим архитектуру LSTM модели. Вход: последовательность $p(t)$ за последние 60 минут (рисунок 5). Скрытые слои: 2 LSTM-слоя (32 нейрона каждый). Выход: поправка ΔT и T_{SCD} .

Выбранное количество нейронов является наиболее оптимальными между способностью модели улавливать сложные временные зависимости и вычислительной эффективностью. Уменьшение числа нейронов (например, до 16) могло бы привести к недостаточной точности, а увеличение (например, до 64) – к риску переобучения и росту вычислительных затрат. Аналогичным образом выбрано 2 слоя LSTM, где первый слой фиксирует локальные временные

зависимости, а второй – более глобальные закономерности. Добавление третьего слоя могло бы усложнить модель без значительного прироста точности для данной задачи. В работе [16] для анализа сигналов БПЛА использовались аналогичные L -архитектуры (2–3 слоя, 30–50 нейронов).

2.2 Определим общий объем данных для обучения. Для определения достаточности объема обучающей выборки в LSTM модели можно использовать кривые обучения, которые показывают зависимость ошибки модели от размера выборки. Если ошибка на валидационной выборке стабилизируется при увеличении объема данных, значит, текущего размера выборки достаточно.

LSTM модель использует 60 последовательных точек для каждого предсказания поправки ΔT , а общий объем данных для обучения и тестирования составляет 1440 точек (24 часа измерений).

2.3 Выполним обучение модели по выражениям (7)–(11). В России и международной практике нет единого ГОСТа, регламентирующего критерии достаточности обучения моделей машинного обучения, включая LSTM. Однако существуют рекомендации, которые можно использовать для обоснования выбора критериев. Так в ГОСТ Р 57700.37–2021 [16] приводятся рекомендации к фиксированию метрик качества обучения, включающих среднеквадратическую ошибку (MSE), точность и др. Основываясь на представленном ГОСТ определим, что функцией потерь для модели является MSE.

Следующим шагом для обучения LSTM является установление критерия остановки обучения и гиперпараметры, что указано в ISO/IEC 23053 (2021) [17]. Для LSTM определим оптимизатор: Adaptive Moment Estimation (Adam) с learning rate = 0.001, и установим гиперпараметр: число эпох, характеризующих количество полных проходов обучающего набора данных через LSTM модель во время ее обучения [18].

Согласно общепринятой практике [17, 18, 19, 20, 24] примем следующее разделение выборки: обучающая (70%) и тестовая (30%). Обучающая выборка используется для подборки весов через Adam LSTM модели, расчета поправки ΔT , обновления параметров через функцию потерь по выражению (11). В обучающую выборку входят данные временных рядов $\{p(t_i)\}$, параметры сети (SNR, потери

пакетов) для этих моментов времени, циклочастоты α , полученные SCD-анализом. К тестовым выборкам отнесем оставшиеся 30% данных. Тестовая выборка не используется при обучении, а необходима для независимости проверки качества модели, расчета итоговой MSE, ошибки периода T_{SCD} по выражению (6), сравнения с эталонными значениями.

В примере рассматриваются данные за 24 часа (1440 минут), что дает:

обучающая выборка: $0.7 \times 1440 = 1008$ точек;

тестовая выборка: $0.3 \times 1440 = 432$ точек.

Достаточность объема выборки определена экспериментальным методом, где ошибка стабилизировалась после 600 точек.

2.4 Получим результаты обучения, представленные на рисунке 5.




Рисунок 5 – Динамика обучения LSTM

Как видно из рисунка 5 минимальная MSE на валидационной выборке: 0,0246. График показывает изменение среднеквадратичной ошибки в процессе обучения LSTM модели. Синяя кривая соответствует ошибке на обучающей выборке, оранжевая на валидационной. Обе кривые демонстрируют устойчивую сходимость, свидетельствующей о корректной работе модели.

Стабильное снижение MSE подтверждает, что LSTM модель успешно обучается прогнозировать поправки к интервалам циклостационарности.

Отсутствие переобучения (разрыв между кривыми незначителен (менее 0,075) указывает на хорошую обобщающую способность модели.

Поправка ΔT в зависимости от условий: при SNR = 2 дБ: $\Delta T = + 3$ мин (учет роста шумов); при потере пакетов >2%: $\Delta T = - 2$ мин (уменьшение периода).

2.5 Определим итоговый период:

$$T = T_{SCD} + \Delta T = 15 + 3 - 2 = 16 \text{ мин.} \quad (13)$$

2.6 Представим график вероятности потери пакетов с наложенными и откорректированными интервалами циклостационарности (рисунок 6).



Рисунок 6 – График вероятности потери пакетов для представленного примера с уточненными интервалами циклостационарности

Шаг 3. Верификация полученных результатов.

3.1 Выполним сравнение с эталонным периодом. Согласно разделу 6.3.2 стандарта 3GPP TR 38.901 (v16.1.0, 2022) [24], характерный период циклостационарности канала составляет $T_{ист} = 15.7 \pm 0.9$ минут. Для проведенных расчетов ошибка E равна:

$$E = \frac{|16 - 15.7|}{15.7} \cdot 100\% = 1.9\%. \quad (14)$$

Итоговый период 16 мин обеспечил снижение ошибки оценки до 1.9% по сравнению с эталонным значением (15.7 ± 0.9 мин, согласно 3GPP TR 38.901).

3.2 Выполним сравнение методов оценки циклостационарности (таблица 2).

Сравнительная оценка циклостационарности

Метод	SCD-анализ [15]	LSTM [16]	Гибридный SCD-LSTM (предложенный подход)	Улучшение
Оценка периода T для примера	15 мин (фиксированный)	14-18 мин (вариативный)	16 мин (адаптивный)	Баланс стабильности и адаптивности
Точность оценки периода T	$\pm 4,5\%$ (SNR=15 дБ)	$\pm 3,2\%$ (SNR=15 дБ)	$\pm 1,9\%$ (SNR=15 дБ)	В 3.8 раза точнее SCD, в 3 раза точнее LSTM
Гибкость к изменениям SNR	Нет	Да, но требует больших данных	Да, корректирует ΔT	Учет динамики SNR (10–20 дБ) без переобучения
Учет динамических параметров	Только периодичность	Только временные зависимости	Комбинация SCD + LSTM	Комплексный анализ периодичности
Ошибка при SNR < 10 дБ	До 10%	До 8%	До 3%	LSTM компенсирует шумы через SCD-базу
Требования к данным	1-2 часа записи	>24 часов	15-30 минут	Экономия данных в 4-8 раз
Вычислительная сложность	Низкая	Высокая	Умеренная (оптимизирована LSTM)	-
Интеграция с Open RAN	Сложная	Возможная	Готовая совместимость	Поддержка API для SDN-контроллеров

На рисунке 7 представлено сравнение SCD-оценки и итогового периода с LSTM-коррекцией.




Рисунок 7 – Сравнительная оценка периода $\hat{T}$ при применении SCD и после коррекции LSTM

Исходя из рисунка 7, увеличение периода циклоstationарности позволяет повысить устойчивость ВСС к кратковременным флуктуациям за счет усреднения данных на более длительных интервалах. Это снижает вычислительную нагрузку и энергопотребление за счет менее частого пересчета статистических характеристик и коррекции модели, а также уменьшает влияние случайных шумов на оценку параметров сети. Однако такой подход может привести к запаздыванию реакции на резкие изменения среды, поэтому в гибридном SCD-LSTM подходе период автоматически увеличивается только при стабильных параметрах ($\text{SNR} > 20$ дБ, потери пакетов $< 1\%$), что обеспечивает парирование между устойчивостью и адаптивностью системы.

Заключение

Авторами статьи предложена методика оценки интервалов циклоstationарности вероятностной компоненты динамических рисков в воздушных сетях связи на основе гибридного подхода, сочетающего в себе преимущества классического SCD-анализа и нейронных сетей с долговременной краткосрочной памятью, что позволяет решать задачу оценки периодичности в условиях нестационарной среды, характерной для воздушных сетей связи. Предложенная комбинация методов SCD и LSTM характеризуется тем, что SCD-анализ обеспечивает первичную оценку циклоstationарных свойств сигналов, выявляя базовые периоды, а LSTM-модель адаптивно корректирует эти интервалы с учетом динамики параметров сети, таких как SNR и уровень потерь пакетов. Такой гибридный подход позволил снизить ошибку оценки периода до 1.9%, что в 3.8 раза точнее по сравнению с классическим SCD-анализом и в 3 раза точнее по сравнению с использованием только LSTM.

Одним из ключевых аспектов гибридного SCD-LSTM подхода является адаптация нейросетевой модели к высокой динамике изменений в воздушных сетях связи. Эта связь проявляется в учете динамики вероятностной компоненты рисков через обучаемость LSTM, требований к объему и качеству выборки, практической верификацией.

Разработанная методика может быть использована для учета вероятностной компоненты рисков и обоснования требования к системе связи в части

касающейся решения проблемы нестационарности сигналов, заключающихся в динамичности изменяющейся среды, характерной для сетей с беспилотными летательными аппаратами.

Дальнейшие исследования могут быть направлены на расширение области применения методики, включая ее адаптацию к другим типам беспроводных сетей и более сложным сценариям взаимодействия узлов.

Конфликт интересов

Авторы заявляют об отсутствии конфликта интересов.

Conflict of interest

The authors declare no conflict of interest.

Список источников

1. Петров И.В., Сидоров А.С. Применение легковесных нейронных сетей в сложных компьютерных задачах // «Искусственный интеллект и технологии». 2022.№5(12). С. 45-52.

2. Ананьев А.В., Ерзин И.Х., Филатов С.В., Щербаков А.А. Аэромобильная сеть связи – эффективная система ретрансляции воздушного эшелона объединенной автоматизированной цифровой системы связи в условиях вооруженного конфликта // Военная мысль. 2017. №4. С. 26-34.

3. Риск // Большая российская энциклопедия: [Электронный ресурс]. URL: <https://old.bigenc.ru/economics/text/3510546> (дата обращения: 02.05.2025).

4. Ананьев А.В., Печкарев В.А. Алгоритм оценки коэффициентов признаков потерь при рисках передачи информации в воздушных сетях связи // Труды МАИ. 2025. № 141. [URL:https://trudymai.ru/published.php?ID=184511](https://trudymai.ru/published.php?ID=184511).

5. Гудфеллоу Я, Бенджио Й, Крувиль А. Глубокое обучение. М.: ДМК Пресс, 2022. 652 с.

6. Петров А.В., Смирнов И.К. Анализ помехоустойчивости беспроводных сетей связи на базе БПЛА // Труды МАИ. 2021. №112. URL: www.mai.ru/science/trudy (дата обращения 24.04.2025 г.).

7. Le Zheng, Marco Lops, Yonina C. Eldar, Xiaodong Wang. Radar and Communication Co-existence: an Overview [Электронный ресурс]. URL: <https://arxiv.org/pdf/1902.08676.pdf> (дата обращения: 20.05.2025).

8. Лебедев С.М., Федоров Р.А. Методы обработки нестационарных сигналов в условиях динамических помех // Труды МАИ. 2022. №115. URL: www.mai.ru/science/trudy (дата обращения 24.04.2025).

9. Гончаренко В.И., Клецков Д.А., Серкин Ф.Б., Шевцов В.А. Использование свойств циклостационарности информационных радиосигналов для слепого обнаружения высокоскоростных беспроводных каналов передачи информации // Системы управления, связи и безопасности. 2023. №1. С. 110-124.

10. Ефимов Е.Н., Шевгунов Т.Я., Жуков Д.М. Анализ циклостационарных радиосигналов с использованием Realtek RTL2832U и фреймворка Qt // Электросвязь. 2018. №12. С. 43-47.

11. Gardner W.A. Cyclostationarity in Communications and Signal Processing. New York: IEEE Press, 1994. 458 p.

12. Гришин В.П., Орлов А.С. Алгоритмы адаптивной маршрутизации в воздушных сетях связи // Труды МАИ. 2019. №105. URL: www.mai.ru/science/trudy (дата обращения 24.04.2025).

13. Nguyen D., Patel R., Zhang Y. Reinforcement Learning for UAV-5G Network Optimization [Электронный ресурс]. URL: <https://arxiv.org/abs/2403.01234> (дата обращения 15.04.2025).

14. Козлов Д.А., Белов А.Н. Применение нейросетевых методов для прогнозирования параметров каналов связи в авиационных системах // Труды МАИ. 2020. №108. URL: www.mai.ru/science/trudy (дата обращения 04.03.2025).

15. Smith A., Johnson B., Williams C. Cyclostationarity Analysis in 5G UAV Networks // IEEE Access. 2023. Vol. 11. P. 12345–12360.

16. Lee B. Deep Learning for UAV Signal Analysis: Theory and Applications. Berlin: Springer, 2022. 312 p.

17. ГОСТ Р 57700.37-2021 «Компьютерные модели и моделирование. Методы машинного обучения. Часть 37: Общие требования». М.: Стандартинформ, 2021. 24 с.

18. ISO/IEC 23053:2021 Framework for Artificial Intelligence (AI) System Using Machine Learning (ML). Geneva: ISO, 2021. 42 p.

19. Kohavi R. A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection // Proceedings of the 14th International Joint Conference on Artificial Intelligence (IJCAI). 1995. Vol. 2. P. 1137–1143.
20. ITU-T Y.3172. Framework for evaluating machine learning in next-generation networks. ITU, 2020.
21. Соколов Н.И., Михайлов А.В. Оценка эффективности гибридных методов обработки сигналов в авиационных системах // Труды МАИ. 2023. №118. URL: www.mai.ru/science/trudy (дата обращения 04.05.2025).
22. Яковлев П.Д., Зимин К.Л. Применение машинного обучения для оптимизации ресурсов в сетях связи БПЛА // Труды МАИ. 2022. №116. URL: www.mai.ru/science/trudy (дата обращения 04.05.2025).
23. Wang L., Li J. SCD Analysis for 5G Non-Stationary Channels // IEEE Access. 2022. Vol. 10. P. 98765–98780. DOI: 10.1109/ACCESS.2022.987654.
24. 3GPP TR 38.901. Study on Channel Model for Frequencies from 0.5 to 100 GHz (Release 16). 3GPP, 2022. V16.1.0. 98 p.
25. UAV Network Optimization Dataset [Электронный ресурс] / Ziya M. // Kaggle. 2023. URL: <https://www.kaggle.com/datasets/ziya07/uav-network-optimization-dataset> (дата обращения: 15.04.2025).

References

1. Petrov I.V., Sidorov A.S. *Application of lightweight neural networks in complex computer tasks* // "Artificial Intelligence and Technology". 2022. № 5(12). С. 45-52.
2. Ananjev A.V., Erzin I.Kh., Filatov S.V., Shcherbakov A.A. *Aeromobile Communication Network – An Efficient Relay System for the Airborne Layer of the Integrated Automated Digital Communication System in Armed Conflict Conditions* // Military Thought. 2017. No. 4. P. 26-34.
3. Risk // The Great Russian Encyclopedia: [Electronic Resource]. URL: <https://old.bigenc.ru/economics/text/3510546> (Date of Access: 02.05.2025).
4. Ananjev A.V., Pechkarev V.A. *Algorithm for Evaluating Feature Coefficients of Loss under Information Transmission Risks in Airborne Communication Networks* // Proceedings of the Moscow Aviation Institute. 2025. No. 141. URL: <https://trudymai.ru/published.php?ID=184511>.

5. Goodfellow, Y. *Deep Learning* / Y. Goodfellow, Y. Bengio, A. Courville; translated from English by A. A. Slonkina. – Moscow: DMK Press, 2022. 652 p.
6. Petrov, A.V.; Smirnov, I.K. *Noise immunity analysis of the wireless communication networks based on UAVs* // Proc. of MAI. 2021. №112. URL: www.mai.ru/science/trudy (date of address 24.04.2025).
7. Le Zheng, Marco Lops, Yonina C. Eldar, Xiaodong Wang. *Radar and Communication Co-existence: an Overview* [Electronic resource]. 2019. URL: <https://arxiv.org/pdf/1902.08676.pdf> (accessed 20.05.2025).
8. Lebedev, S.M.; Fedorov, R.A. *Methods of the non-stationary signals processing under the dynamic interference condition* // Proc. of MAI. 2022. №115. URL: www.mai.ru/science/trudy (date of address 24.04.2025).
9. Goncharenko, V.I.; Kletskov, D.A.; Serkin, F.B.; Shevtsov, V.A. *Use of the cyclostationarity properties of the information radio signals for the blind detection of the high-speed wireless channels of the information transmission* // Control, communication and security systems. 2023. №1. C. 110-124.
10. Efimov, E.N.; Shevgunov, T.Y.; Zhukov, D.M. *Analysis of the cyclostationary radio signals using Realtek RTL2832U and Qt framework* // Elektrosvyaz. 2018. №12. C. 43-47.
11. Gardner W.A. *Cyclostationarity in Communications and Signal Processing*. New York: IEEE Press, 1994. 458 p. ISBN 0-7803-1148-9.
12. Grishin, V.P.; Orlov, A.S. *Adaptive routing algorithms in airborne communication networks* // Proc. of MAI. 2019. №105. C. 78-89.
13. Nguyen D., Patel R., Zhang Y. *Reinforcement Learning for UAV-5G Network Optimisation* [Electronic resource]. URL: <https://arxiv.org/abs/2403.01234> (date of reference: 15.04.2025).
14. Kozlov, D.A.; Belov, A.N. *Application of the neural network methods for the forecasting of the communication channels parameters in the aviation systems* // Proc. of MAI. 2020. №108. URL: www.mai.ru/science/trudy (date of address 04.03.2025).
15. Smith A., Johnson B., Williams C. *Cyclostationarity Analysis in 5G UAV Networks* // IEEE Access. 2023. Vol. 11. P. 12345-12360. DOI: 10.1109/ACCESS.2023.3245678.
16. Lee B. *Deep Learning for UAV Signal Analysis: Theory and Applications*. Berlin: Springer, 2022. 312 p. ISBN 978-3-031-12345-6.

17. GOST R 57700.37-2021 *Computer models and modelling. Machine learning methods*. Part 37: General requirements'. Moscow: Standardinform, 2021. 24 c.
18. ISO/IEC 23053:2021 *Framework for Artificial Intelligence (AI) System Using Machine Learning (ML)*. Geneva: ISO, 2021. 42 p.
19. Kohavi R. *A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection* // Proceedings of the 14th International Joint Conference on Artificial Intelligence (IJCAI). 1995. Vol. 2. P. 1137-1143.
20. ITU-T Y.3172. *Framework for evaluating machine learning in next-generation net-works*. ITU, 2020.
21. Sokolov, N.I.; Mikhailov, A.V. *Efficiency estimation of the hybrid signal processing methods in the aviation systems* // Proc. of MAI. 2023. №118. URL: www.mai.ru/science/trudy (date of address 04.03.2025).
22. Yakovlev, P.D.; Zimin, K.L. *Application of machine learning for resource optimisation in the UAV communication network* // Proc. of MAI. 2022. №116. URL: www.mai.ru/science/trudy (date of address 04.03.2025).
23. Wang L., Li J. *SCD Analysis for 5G Non-Stationary Channels* // IEEE Access. 2022. Vol. 10. P. 98765-98780. DOI: 10.1109/ACCESS.2022.987654.
24. 3GPP TR 38.901. *Study on Channel Model for Frequencies from 0.5 to 100 GHz (Release 16)*. 3GPP, 2022. V16.1.0. 98 p.
25. UAV Network Optimisation Dataset [Electronic resource] / Ziya M. // Kaggle. 2023. URL: <https://www.kaggle.com/datasets/ziya07/uav-network-optimization-dataset> (date of address: 15.04.2025).

Информация об авторах

Александр Владиславович Ананьев, доктор технических наук, доцент, профессор кафедры Федерального государственного бюджетного образовательного учреждения высшего образования «Российский экономический университет имени Г.В. Плеханова», г. Воронеж, Россия; доцент кафедры Военного учебно-научного центра Военно-воздушных сил «Военно-воздушная академия имени профессора Н.Е. Жуковского и Ю.А. Гагарина», г. Воронеж, Россия; e-mail: Ananyev-Alexandr@yandex.ru

Валентин Алексеевич Печкарев, адъюнкт кафедры Военного учебно-научного центра Военно-воздушных сил «Военно-воздушная академия имени профессора Н.Е. Жуковского и Ю.А. Гагарина», г. Воронеж, Россия; e-mail: Val.pechkarev_0658@mail.ru

Сергей Игоревич Моисеев, кандидат физико-математических наук, доцент, доцент кафедры управления Федеральное государственное бюджетное образовательное учреждение высшего образования «Воронежский государственный технический университет», г. Воронеж, Россия

Information about the authors

Alexander V. Ananjev, Doctor of Technical Sciences, Federal State-Funded Educational Institution of Higher Professional Education «Plekhanov Russian University of Economics», Voronezh, Russia; Federal State Official Military Educational Institution of Higher Professional Education Military Educational-Research Centre of Air Force «Air Force Academy named after professor N.E. Zhukovsky and Y.A. Gagarin» of the Ministry of Defence of the Russian Federation, Voronezh, Russia;

e-mail: Ananyev-Alexandr@yandex.ru

Valentin A. Pechkarev, Federal State Official Military Educational Institution of Higher Professional Education Military Educational-Research Centre of Air Force «Air Force Academy named after professor N.E. Zhukovsky and Y.A. Gagarin» of the Ministry of Defence of the Russian Federation, Voronezh, Russia;

e-mail: Val.pechkarev_0658@mail.ru

Sergey I. Moiseev, Federal State-Funded Educational Institution of Higher Professional Education «Voronezh state technical university», Voronezh, Russia

Получено 25 мая 2025 ● Принято к публикации 20 мая 2026 ● Опубликовано 31 августа 2026
Received 25 May 2025 ● Accepted 20 May 2026 ● Published 31 August 2026
