

**ОБЩАЯ ЭКСПЕРИМЕНТАЛЬНАЯ
ТЕХНИКА**

УДК 681.586.586.5; 681.518.3

**СРАВНИТЕЛЬНЫЙ АНАЛИЗ АЛГОРИТМОВ СНИЖЕНИЯ
ПОГРЕШНОСТЕЙ ИЗМЕРЕНИЯ ЦЕНТРАЛЬНОЙ ЧАСТОТЫ
СПЕКТРА СИГНАЛА ОБРАТНОГО РАССЕЯНИЯ
МАНДЕЛЬШТАМА-БРИЛЛЮЭНА В СТАНДАРТНЫХ
ОПТИЧЕСКИХ ВОЛОКНАХ¹**

© 2026 г. И. В. Богачков^{а, *}, Н. И. Горлов^{б, **}, Э. В. Гармаева^с,
Е. Т. Китова^д

^а*Омский государственный технический университет*

Россия, 644050, Омск, просп. Мира, 11

^б*Сибирский государственный университет телекоммуникаций и информатики*

Россия, 630102, Новосибирск, ул. Кирова, 86

^с*Бурятский институт инфокоммуникаций (филиал) Сибирского государственного
университета телекоммуникаций и информатики*

Россия, 670031, Улан-Удэ, ул. Трубочеева, 152

^д*Новосибирский государственный технический университет*

Россия, 630073, Новосибирск, просп. К. Маркса, 20

^{*}*e-mail: bogachkov@mail.ru*

^{**}*e-mail: gorlovnik@yandex.ru*

Поступила в редакцию 20.04.2026 г.

После доработки 11.05.2026 г.

Принята к публикации 18.06.2026 г.

Распределенные волоконно-оптические датчики на принципе обратного рассеяния Мандельштама-Бриллюэна осуществляют мониторинг температуры и деформации посредством измерения основных параметров спектра усиления. Точное определение центральной частоты спектра является критической задачей в системах распределённого зондирования. Проведен сравнительный анализ алгоритмов уменьшения погрешностей измерения центральной частоты спектра сигнала. Представлен комплексный сравнительный анализ современных алгоритмов обработки спектров Мандельштама-Бриллюэна, направленных на повышение точности измерения центральной частоты. Проанализированы традиционные методы нелинейного приближения, корреляционные методы, адаптивные процедуры и нейросетевые подходы. Представлена математическая модель погрешностей измерения, учитывающая вклад шумовой составляющей, систематических искажений и дискретизации частотной сетки. Дана

¹ Международная конференция “Оптическая рефлектометрия, метрология и сенсорики 2026”, Россия, Пермь, 26–28 мая 2026 г.

оценка метрологических характеристик алгоритмов. Предложена оптимальная стратегия выбора алгоритма в зависимости от требований к пространственному разрешению, дальности измерения и времени реакции системы. Результаты анализа и предложенная методология выбора оптимального алгоритма могут быть полезными для разработки практических систем волоконно-оптического мониторинга с улучшенными метрологическими характеристиками. Результаты исследования указывают на необходимость адаптивного подхода к выбору алгоритма обработки сигналов в системах распределённого зондирования, что важно для повышения надёжности мониторинга критической инфраструктуры в условиях реальных развёртываний.

Ключевые слова: распределенный волоконно-оптический датчик, рассеяния Мандельштама-Бриллюэна, распределённое зондирование, корреляционные методы, адаптивные процедуры, нейросетевые подходы.

1. ВВЕДЕНИЕ

Распределенное волоконно-оптическое зондирование на основе бриллюэновского рассеяния стало мощной технологией для непрерывного мониторинга температуры и деформации вдоль оптических волокон протяженностью от десятков до сотен километров. Основной принцип измерения основан на обнаружении сдвигов частоты в спонтанных или вынужденных бриллюэновских рассеянных сигналах по мере изменения этих параметров вдоль длины волокна [1].

Основным параметром, определяющим температуру и деформацию в датчиках на основе рассеяния Бриллюэна, является центральная частота спектра усиления Бриллюэна, которая также называется бриллюэновским частотным сдвигом (БЧС, BFS – Brillouin Frequency Shift). Линейная зависимость BFS от указанных физических параметров записывается следующим образом:

$$\nu_B = \nu_{B0} + C_T \cdot \Delta T + C_\varepsilon \cdot \Delta \varepsilon, \quad (1)$$

где ν_{B0} – опорная частота Бриллюэна при референтных условиях; $C_T = 1.07 \text{ МГц}/^\circ\text{C}$ и $C_\varepsilon = 0.046 \text{ МГц} / \mu\varepsilon$ – коэффициенты температурной и деформационной чувствительностей, соответственно, для стандартного оптического волокна; ΔT и $\Delta \varepsilon$ – изменения температуры и относительной деформации [1, 2].

Точность измерения центральной частоты спектра напрямую определяет метрологические характеристики всей системы. Современные требования к промышленным датчикам предполагают достижение пространственного разрешения в сантиметровом диапазоне при одновременной дальности измерения до 50-100 км и относительной погрешности определения BFS не более 0.1%. Достижение таких параметров требует разработки специализированных алгоритмов обработки сигналов, способных эффективно подавлять различные источники погрешностей [2].

Основными факторами, ограничивающими точность измерения BFS, являются:

- аддитивный белый гауссов шум на этапе детектирования слабых сигналов обратного рассеяния;

- систематические искажения спектра, вызванные нелинейностями в оптическом тракте и эффектами взаимодействия импульсов;
- дискретизация по частоте, приводящая к ограничению разрешающей способности и появлению квантования погрешности;
- неполное использование спектра при ограниченном диапазоне частотного сканирования;
- флуктуации параметров оптического тракта (изменения температуры, вибрации).

Традиционный подход к извлечению BFS основан на нелинейном приближении экспериментальных данных аналитическими функциями (лоренцева, гауссова, псевдо-Фойгт-профили) с последующим определением положения максимума. Однако такие методы имеют существенные ограничения: высокую вычислительную сложность итерационных процедур, чувствительность к выбору начальных приближений и риск сходимости к локальным экстремумам при низком отношении сигнал/шум (SNR).

В последние годы активно развиваются альтернативные подходы, включая субспейсовые методы, корреляционные алгоритмы, адаптивные процедуры и нейросетевые архитектуры. Каждый из этих методов имеет свои преимущества и недостатки, однако систематическое сравнение их метрологических характеристик в единой методологической рамке отсутствует в литературе.

Целью настоящей работы является проведение комплексного сравнительного анализа современных алгоритмов уменьшения погрешностей измерения центральной частоты спектра с формулировкой рекомендаций по их оптимальному применению в зависимости от технических требований к системе.

Критерии и методика сравнительного анализа алгоритмов

При сравнении алгоритмов рассматриваются несколько критериев, позволяющих количественно оценить уменьшение погрешности при определении центральной частоты спектра.

- Систематическая погрешность оценки частоты: среднее смещение оценённой частоты относительно истинной (эталонной) BFS (в мегагерцах).
- Случайная погрешность: дисперсия или стандартное отклонение оценки BFS при повторных измерениях в одинаковых условиях; часто анализируется как функция отношения сигнал/шум (ОСШ).
- Суммарная погрешность: комбинированная оценка, учитывающая систематическую и случайную составляющие (например, по методикам ГСИ/МИ),

вычисляемая через корень из суммы квадратов и/или с использованием доверительных интервалов.

- Чувствительность к параметрам сигнала: зависимость погрешности от ширины линии Бриллюэна, шага дискретизации по частоте, времени интегрирования и других параметров.

Помимо «чистой» погрешности, в сравнительный анализ включаются следующие характеристики алгоритма как процедуры обработки.

- Стойкость к шуму и паразитным компонентам: степень сохранения точности при снижении ОСШ, при наличии модовых «хвостов», спекл-шума и других помех.

- Робастность к отклонению формы линии от идеальной лоренцовой: устойчивость при асимметрии линии или при наложении нескольких компонент.

- Вычислительная сложность: время обработки одного спектра (или всей трассы) и требования к вычислительным ресурсам, что критично для реальных распределённых БР-датчиков.

- Автоматизируемость и чувствительность к начальному приближению: необходимость подбора стартовых параметров, чувствительность алгоритма к грубым оценкам и возможность полной автоматической работы.

Ключевая методика сравнительного анализа — контролируемое добавление сгенерированного цифрового шума по заданному закону распределения интенсивности для каждой частоты отдельно при установленном SNR.

2. КЛАССИЧЕСКИЕ МЕТОДЫ СПЕКТРАЛЬНОЙ АППРОКСИМАЦИИ

Все алгоритмы определения параметров спектра можно условно разделить на три группы:

- методы аппроксимации специальными функциями — прямая аппроксимация спектра одной из стандартных функций (Лоренца, Гаусса, Фойгта и псевдо-Фойгта);
- методы интерполяции — восстановление функции в промежуточных точках;
- методы кросс-корреляции — поиск максимума путём корреляции с эталонной функцией.

Методы первой группы остаются наиболее распространёнными в коммерческих приборах благодаря высокой скорости обработки и встроенной физической интерпретируемости. Однако выбор аппроксимирующей функции значительно влияет на точность извлечения параметров, особенно при низких SNR. Ни одна из четырёх основных функций не является универсально оптимальной. Каждая представляет

компромисс между физической корректностью, вычислительной эффективностью и робастностью к шуму.

В классической теории рассеяния Бриллюэна спектр усиления в режиме слабого усиления описывается функцией Лоренца [3]:

$$g_B(\nu) = \frac{g_0}{1 + 4(\nu - \nu_B)^2 / \Delta \nu_B^2}, \quad (2)$$

где g_0 – пиковое усиление; ν_B – частота сдвига Бриллюэна; $\Delta \nu_B$ – полная ширина спектра на уровне половины максимума (FWHM, Full Width at Half Maximum), обычно составляющая 20–40 МГц для стандартного одномодового волокна.

В спектроскопии Бриллюэна профиль Лоренца описывает внутреннее уширение спектральной линии, обусловленное конечным временем жизни акустического фонона. Для стандартных SMF волокон это время составляет порядка нескольких наносекунд, что приводит к естественной ширине линии на уровне единиц-десятков МГц.

Достоинства [3]:

- простая аналитическая форма с минимальным числом параметров (4);
- быстрое вычисление и минимальные требования к памяти;
- хорошая физическая интерпретация параметров.

Недостатки:

- медленная асимптотика (убывает как $1/\nu^2$ на крыльях);
- плохо описывается доплеровское уширение (температурные эффекты);
- на экспериментальных спектрах часто наблюдается значительное отклонение в крыльях линии;
- требуется итеративная оптимизация (метод Levenberg-Marquardt).

Сущность метода Левенберга-Марккварта заключается в решении задачи нелинейных наименьших квадратов функционала [4]

$$S(\theta) = \sum_{i=1}^N r_i(\theta)^2, r_i(\theta) = y_i - I(\nu_i; \theta), \quad (3)$$

где N – количество частот; $I(\nu_i; \theta)$ – теоретическое значение функции Лоренца на частоте ν_i ; $\theta = (A, \nu_B, \Gamma)$ – вектор амплитуды, бриллюэновского сдвига частоты и ширины спектральной линии; y_i – экспериментальное значение спектра на частоте ν_i , $i=1, 2, \dots, N$.

В реальных условиях наблюдается искажение идеальной формы вследствие неоднородного уширения и систематических искажений, что приводит к

необходимости использования более сложных моделей. Так, при высоких уровнях усиления (более 10 дБ) спектр приобретает гауссов профиль [5]:

$$g_G(\nu) = g_0 \exp\left(-\frac{2(\nu - \nu_B)^2}{\Delta \nu_B^2}\right). \quad (4)$$

Этот переход обусловлен нелинейными эффектами истощения накачки и насыщением усиления в системах с конечной полосой пропускания.

Достоинства [6]:

- быстрое убывание на крыльях (экспоненциальное);
- хорошо описывается центральную часть пика в условиях доминирующего доплеровского уширения;
- аналитические формулы для многих операций (свёртка, интегрирование).

Недостатки:

- существенные искажения при аппроксимации широкополосных спектров;
- ошибка может быть на порядок выше, чем для функции Лоренца [7].

Реальные спектры РМБ в стандартных оптических волокнах содержат обе компоненты: лоренцеву (от акустических потерь) и гауссову (от однородного уширения, температурных флуктуаций и дефектов в материале).

Функция Фойгта $V(\nu; \sigma; \gamma)$ достаточно точно моделирует эту суперпозицию в виде свёртки гауссова и лоренцева профилей по частоте [8]:

$$V(\nu; \sigma; \gamma) = \int_{-\infty}^{\infty} G(\nu'; \sigma) L(\nu - \nu'; \gamma) d\nu', \quad (5)$$

где $G(\nu'; \sigma)$ - гауссов профиль; $L(\nu - \nu'; \gamma)$ - лоренцев профиль; σ - среднеквадратичная ширина (стандартное отклонение); γ - половина ширины на полувысоте (HWHM).

В литературе по бриллюэновским распределённым датчикам спектр усиления обратного рассеяния часто записывают в Voigt-форме [9]:

$$g_B(\nu) = g_{BM} V(\nu - \nu_B; \sigma_G, \gamma_L), \quad (6)$$

где g_{BM} - максимальное значение коэффициента усиления (или нормированная амплитуда мощности обратного сигнала); ν_B - центральная частота (BFS), зависящая от температуры и деформации; σ_G - параметр гауссовой компоненты (описывает эффективное доплеровское инструментальное уширение); γ_L - параметр лоренцевой компоненты (описывает акустическое затухание, т.е. «истинную» бриллюэновскую ширину).

Достоинства:

- максимальная физическая корректность для РМБ-спектров;
- наименьшая ошибка аппроксимации экспериментальных данных ($S = 8.9 \cdot 10^{-3}$) [9];

- гибкость в описании различных режимов (чистые функции Лоренца или Гаусса в предельных случаях).

Недостатки:

- вычисление требует специализированных алгоритмов;
- завышенные требования к вычислительным ресурсам (в 50–100 раз медленнее Лоренца);
- возможна неустойчивость при чрезмерно зашумленных данных.

Профиль псевдо-Фойгта представляет собой линейную комбинацию профилей Гаусса и Лоренца с параметром смешивания $\eta \in [0, 1]$:

$$V_p(\nu) = \eta \cdot L(\nu) + (1 - \eta) \cdot G(\nu), \quad (7)$$

где η – параметр взвешивания, определяющий долю лоренцевой компоненты.

Полный профиль Voigt представляет собой свёртку гауссовой и лоренцевой функций, он используется для описания сложных спектров с несколькими механизмами уширения.

Достоинства:

- простое аналитическое выражение, быстрое вычисление (сопоставимо по скорости с вычислением для функции Лоренца);
- хорошее описание реальных спектров при $\eta \approx 0.5–0.8$ для РМБ;
- приемлемая точность ($S = 9.5 \cdot 10^{-3}$) при существенном снижении вычислительных затрат;
- легко встраивается в стандартные программные пакеты.

Недостатки:

- феноменологический характер; не является точной свёрткой;
- при экстремальных значениях η (очень близких к 0 или 1) может давать худшие результаты, чем профили Гаусса или Лоренца;
- параметр η требует отдельной оптимизации.

Сравнение методов аппроксимации по точности представлено в табл. 1.

Таблица 1. Сравнение методов аппроксимации по точности

Функция	Ошибка ($S \cdot 10^4$)	Применимость в РМБ	Вычислительная сложность
Лоренца	153	Хорошая	1×(быстро)

Гаусса	613	Неприменима	1×(быстро)
Фойгта	89	Отличная	50–100×(медленно)
Псевдо-Фойгта	95	Хорошая	1–2×(оптимально)

3. ПАРАБОЛИЧЕСКАЯ АППРОКСИМАЦИЯ ОКРЕСТНОСТИ МАКСИМУМА СПЕКТРА

Подгонка параметров квадратичной (параболической) функции занимает центральное место в алгоритмической цепочке обработки зашумленных спектров спонтанного рассеяния Мандельштама–Бриллюэна (РМБ) в волоконных оптических датчиках, таких как BOTDR (Brillouin Optical Time Domain Reflectometry) и BOTDA. Её главное предназначение – точное и быстрое извлечение пика спектра с целью определения BFS, который линейно связан с температурой и деформацией оптического волокна. Вблизи пика огибающая спектра хорошо аппроксимируется параболой, что позволяет заменить вычислительно сложную нелинейную подгонку лоренцевой или фойгтовой функции простой полиномиальной регрессией.

В окрестности пика экспериментального спектра профиль аппроксимируется параболой (квадратичной функцией):

$$y = af^2 + bf + c, \quad (8)$$

где коэффициенты a, b, c определяются методом наименьших квадратов.

Предположим, что спектр представлен набором точек данных $\{(x_i, y_i)\}_{i=1}^N$, содержащих аддитивный гауссов шум с дисперсией σ_n^2 . Задача квадратичной подгонки решается методом наименьших квадратов:

$$\sum_{i=1}^N \left[y_i - (ax_i^2 + bx_i + c) \right]^2 \rightarrow \min. \quad (9)$$

Система нормальных уравнений, получаемая из условия минимизации, имеет вид [10]

$$\begin{pmatrix} \sum x_i^4 & \sum x_i^3 & \sum x_i^2 \\ \sum x_i^3 & \sum x_i^2 & \sum x_i \\ \sum x_i^2 & \sum x_i & N \end{pmatrix} \begin{pmatrix} a \\ b \\ c \end{pmatrix} = \begin{pmatrix} \sum x_i^2 y_i \\ \sum x_i y_i \\ \sum y_i \end{pmatrix}. \quad (10)$$

Дисперсия извлеченной частоты пика $x_p = -b/(2a)$ зависит от дисперсий коэффициентов подгонки a и b , а также их ковариации.

Дисперсия извлечённого пика (σ_v) зависит от множества факторов:

- длина и положение диапазона частот, используемого для подгонки относительно истинного пика; если диапазон отцентрирован на истинный пик, то дисперсия достигает минимума;

- влияние уровня шума:

$$\sigma_v \propto \frac{1}{\text{SNR}_A}; \quad (11)$$

- влияние частотного шага:

$$\sigma_v \propto \sqrt{d}; \quad (12)$$

- влияние количества точек сканирования:

$$\sigma_v \propto \sqrt{N}. \quad (13)$$

Ключевые преимущества:

- вычисляется за один проход без итераций;
- требует только линейную алгебру (система из 3 уравнений);
- скорость выполнения в 50–200 раз выше, чем у нелинейной подгонки лоренцевой функции;
- параболическая аппроксимация устойчива к шумам при низких SNR — в системах с низким отношением сигнал-шум параболический метод обеспечивает более надёжную оценку, чем простой поиск максимума или лоренцева подгонка.

При реальных экспериментальных исследованиях с BOTDR «Ando AQ 8603» минимальная длительность зондирующего импульса составляла 10 нс, что соответствует реальной разрешающей способности по расстоянию в 1 м.

Длина составленного из различных волокон световода обычно составляла менее 2 км (в том числе 1 км в начале световода – нормализующая катушка из обычного одномодового волокна G.652). Минимальный шаг сканирования по частоте составлял 1 МГц [26–29].

Пример BOTDR-рефлектограммы распределения спектра РМБ вдоль световода, полученного авторами, приведён на рис. 1. Диапазон сканирования по частоте составил от 10.82 ГГц до 11.35 ГГц с шагом по частоте 10 МГц. В правом нижнем углу рефлектограммы показан спектр РМБ в выбранном сечении (на дистанции 1077.18 м), а также указана частота максимума (BFS) – 11.0708 ГГц.

Рис. 1. Пример BOTDR-рефлектограммы распределения спектра РМБ вдоль световода

Сравнение с альтернативными методами представлено в табл. 2 [11].

Таблица 2. Сравнение с альтернативными методами

Метод	Время	Точность	Зависимость от	Применение
-------	-------	----------	----------------	------------

	вычисления		параметров	
Квадратичная подгонка	1× (базовое)	Средняя (около 1–2 МГц ошибка)	Высокая	Реальное время, BOTDR
Лоренцева подгонка	50–100×	Очень хорошая (около 0.05 МГц)	Средняя	Офлайн-анализ
Фойгтова подгонка	100–200×	Отличная	Низкая	Исследования, узкие импульсы

Из таблицы видно, что квадратичная подгонка обменивает небольшую потерю точности на колоссальный выигрыш в скорости, что критично для распределённых датчиков на длинных волокнах (более 1 км). Подгонка параметров квадратичной функции занимает критическую позицию в алгоритме обработки спектров спонтанного рассеяния Мандельштама-Бриллюэна как компромисс между

- скоростью (требование реального времени для длинных датчиков);
- точностью (требуемое разрешение по деформации/температуре);
- простотой реализации (не требует сложных нелинейных оптимизаторов).

Недостатки:

- она менее устойчива к асимметрии пика и к искажению формы (многомодовые/многопиковые волокна, нелинейные и поляризационные эффекты);
- сильно зависит от выбора окна вокруг максимума.

4. КОРРЕЛЯЦИОННЫЕ МЕТОДЫ ОБРАБОТКИ BGS

Основная сложность в извлечении информационных параметров (BFS) из экспериментальных спектров бриллюэновского усиления состоит в необходимости определения позиции пика спектра с высокой точностью при одновременном наличии шума, спектрального уширения и нелинейных искажений. Традиционные методы, основанные на аппроксимации спектра функцией Лоренца с помощью нелинейной оптимизации (метод Левенберга-Маркардта), показывают ограниченную эффективность при низких отношениях сигнал-шум ($SNR < 10$ дБ) или при сильной деформации профиля спектра. Альтернативными являются методы корреляционного анализа, основанные на использовании математических операций свёртки, взаимной корреляции и спектральных модуляций для выделения информационного пика из зашумлённого сигнала. Они привлекательны своей математической строгостью,

физической интерпретируемостью, при этом они демонстрируют превосходную робастность при экстремальных условиях.

Корреляционные методы анализа спектров обратного рассеяния включают в себя множество подходов, среди которых наибольшей эффективностью характеризуются алгоритмы взаимной и обратной корреляции. Сущность первого заключается в вычислении корреляционной функции между теоретической кривой спектрального профиля и экспериментальным спектром, содержащим шумовую компоненту. При такой обработке форма полученной корреляционной кривой в решающей степени определяется морфологией полезного сигнала, в то время как влияние шума оказывается незначительным. Этот подход, получивший в литературе наименование «метод кросс-корреляции» (*Cross-correlation method* – CCM), широко применяется при спектральном анализе в волоконно-оптических датчиках [12].

Пусть эталонная функция $g_r(\nu)$ коррелирует с комбинированным сигналом $g_n(\nu) = g_u(\nu) + n(\nu)$, где $g_u(\nu)$ – неизвестный лоренцев профиль, а $n(\nu)$ – помеховая составляющая с характером случайного шума. Взаимно-корреляционная функция этих сигналов определяется следующим соотношением [12]:

$$\begin{aligned} G_m(\nu) &= g_r(\nu)g_n(\nu) = g_r(\nu)[g_u(\nu) + n(\nu)] = \\ &= g_r(\nu)g_u(\nu) + g_r(\nu)n(\nu) = G_c(\nu) + N_c(\nu). \end{aligned} \quad (14)$$

Рассматриваемое математическое выражение раскладывается на две независимые компоненты: $G_c(\nu)$ отвечает за корреляционный сигнал между двумя совершенными лоренцевыми профилями, в то время как $N_c(\nu)$ характеризует корреляционный отклик идеального профиля в присутствии белого шума. Соотношение между ними эквивалентно отношению сигнал/шум для $G_m(\nu)$. При сопоставлении с базовым спектром BGS обнаруживается, что исходный спектр содержит более высокий уровень шумовых компонент. Вместе с тем, взаимная корреляция формирует в окрестности максимума квазилоренцеву огибающую, обеспечивая значительное ослабление шумовой составляющей.

Альтернативным подходом является метод обратной корреляции (*Backward Correlation* – BWC). Он представляет собой мощный инструмент для определения позиции пика спектра в условиях высокого уровня шума. Фундаментальная идея метода основана на использовании свойства ортогональности сигнала и шума при операции свёртки.

Пусть исходный спектр представлен дискретным набором отсчётов [13]:

$$P_i = P(\nu_0 + i \cdot \Delta\nu), i = 0, 1, \dots, 2N, \quad (15)$$

где ν_0 – минимальная частота спектра; $\Delta\nu$ – шаг сканирования частоты; P_i – плотность мощности обратного рассеяния на частоте ν_i .

Обратный сигнал определяется как зеркальное отражение исходного спектра:

$$P'_i = P_{2N-1-i}. \quad (16)$$

Для каждого целого значения сдвига $k \in [-2N, 2N]$ вычисляется сдвинутый обратный сигнал:

$$P''_i(k) = P'_{i-k}, \quad P'' = 0, \text{ если } i-k \notin [0, 2N]. \quad (17)$$

Свёртка (дискретная обратная корреляция) между прямым и сдвинутым обратным сигналами вычисляется следующим образом:

$$X(k) = \sum_{i=0}^{2N} P_i \cdot P''_i(k) = \sum_{i=0}^{2N} P_i^S \cdot P_i^{nS}(k) + \text{паразитные члены}, \quad (18)$$

где первый член представляет собой произведение полезных сигналов, а остальные члены связаны с шумовыми компонентами.

Коэффициент корреляции Пирсона вычисляется по формуле [14]

$$r(k) = \frac{\langle p \cdot p''(k) \rangle - \langle p \rangle \langle p''(k) \rangle}{\sigma_p \cdot \sigma_{p''(k)}}, \quad (19)$$

где $\langle \cdot \rangle$ – среднее значение; σ – стандартное отклонение.

Максимум коэффициента корреляции соответствует максимуму свёртки при одном и том же значении сдвига k_0 .

BFS вычисляется из найденного значения сдвига k_0 :

$$\nu_b = \nu_0 + \left(N - \frac{k_0}{2} \right) \cdot \Delta\nu. \quad (20)$$

Некоторые другие варианты корреляционных оценок по другим различным методам для вычисления частоты максимума (BFS) были ранее проанализированы в работах [30–34].

Преимущество метода BWC наиболее ярко проявляется при работе с зашумлёнными спектрами. Математически это объясняется тем, что операция свёртки два раза пропускает данные через процедуру "усреднения" соседних точек, что эффективно действует как нелинейный фильтр нижних частот для шумовой компоненты. Экспериментально установлено, что при $\text{SNR} < 2$ дБ метод BWC обеспечивает точность определения BFS ± 0.4 МГц [15].

Этот метод имеет еще несколько существенных преимуществ:

- эффективность при низком SNR — метод дает меньшую ошибку при $\text{SNR} < 20$ дБ по сравнению с традиционными методами поиска максимума, где каждый выброс шума может привести к значительной ошибке;
- простота вычисления — требует только вычисления N корреляций, где N — число отсчётов в спектре;
- не требует усреднения — работает с одиночным спектром без предварительного усреднения данных;
- инвариантность к форме спектра — не зависит от точной формы пика, что делает его устойчивым к асимметричности спектра и артефактам;
- одноэтапная обработка — предварительная очистка сигнала не требуется.

Зависимость критического SNR от шага сканирования показывает, что при меньшем шаге сканирования преимущества метода проявляются в более широком диапазоне SNR [16].

Способы определения спектра РМБ (и BFS) при адаптивном шаге сканирования по частоте, которые позволяют уменьшить время получения результатов измерений в BOTDR, были ранее проанализированы в работах [31, 32, 34].

5. ПРИМЕНЕНИЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ И МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ

В последние годы машинное обучение и, в частности, искусственные нейронные сети (ИНС), стало активно применяться для обработки сигналов в распределённых волоконно-оптических датчиках. ИНС обладают способностью к нелинейному моделированию сложных зависимостей, эффективному подавлению шума и выделению полезных признаков из данных с низким SNR. Это делает их перспективным инструментом для улучшения ключевых метрологических характеристик датчиков РМБ без модификации аппаратной части. Машинное обучение (МО) и особенно глубокое обучение открыло новые возможности для обработки сложных многомерных данных, при этом продемонстрированы выдающиеся результаты в задачах распознавания образов и регрессионного анализа. Интеграция МО в метрологию распределённых волоконно-оптических датчиков позволяет перейти от жестких алгоритмических процедур к адаптивным моделям, способным извлекать скрытые зависимости непосредственно из необработанных или слабо обработанных данных. Это соответствует общей тенденции цифровизации измерительной техники и перехода к интеллектуальным сенсорным системам. За последнее пятилетие методы искусственного интеллекта — от простых искусственных нейронных сетей (ANN) до

сложных архитектур свёрточных сетей (CNN) и физически информированных моделей глубокого обучения – продемонстрировали способность превосходить классические методы по скорости, точности и робастности [17].

Первые успешные применения нейронных сетей к обработке данных BOTDA были основаны на простых полносвязных архитектурах с 1–3 скрытыми слоями. Основная идея заключается в том, что входной слой получает нормализованные значения спектра BGS (обычно 50–150 частотных точек), а выходной слой предсказывает BFS и ширину спектра. На фундаментальном уровне работа ANN сводится к композиции функций, где каждый слой применяет линейное преобразование (матричное умножение) и нелинейное преобразование (функцию активации).

Нейронная сеть состоит из последовательности слоев. Каждый слой выполняет следующее преобразование [18]:

$$Z^{(l)} = W^{(l)} X^{(l-1)} + b^{(l)}, \quad (21)$$

где

- $W^{(l)} \in R^{n_l \times n_{l-1}}$ – матрица весов R -го слоя размером $n_l \times n_{l-1}$;
- $X^{(l-1)} \in R^{n_{l-1} \times m}$ – матрица входных данных для R -го слоя (размер: количество нейронов предыдущего слоя $\times$ количество примеров в мини-пакете);
- $b^{(l)} \in R^{n_l}$ – вектор смещений (bias), добавляемый к каждому столбцу;
- $Z^{(l)} \in R^{n_l \times m}$ – результирующая матрица до применения функции активации.

После вычисления $Z^{(l)}$ поэлементно применяется функция активации:

$$A^{(l)} = \sigma(Z^{(l)}), \quad (22)$$

где σ – функция активации, применяемая независимо к каждому элементу матрицы, а $A^{(l)}$ – активация R -го слоя, которая становится входом для следующего слоя.

Для сети с L слоями полная композиция функций имеет вид [19]

$$A^{(L)} = f_L(A^{(L-1)}) = f_L(f_{L-1}(\dots f_1(X^{(0)})\dots)), \quad (23)$$

где каждая функция f_l представляет собой комбинацию матричного преобразования и функции активации:

$$f_l(X^{(l-1)}) = \sigma(W^{(l)} X^{(l-1)} + b^{(l)}). \quad (24)$$

Функции активации вводят нелинейность в сеть, позволяя ей аппроксимировать нелинейные функции. Без них нейронная сеть была бы эквивалентна одному линейному преобразованию.

Математическое описание искусственной нейронной сети показывает, что она представляет собой композицию чередующихся линейных преобразований (матричные

умножения) и нелинейных преобразований (функции активации). Обучение сети осуществляется через алгоритм обратного распространения ошибок. Современные методы оптимизации способны адаптивно регулировать скорости обучения для каждого параметра, что обеспечивает быструю и стабильную сходимость. ANN особенно эффективны для спектров, искажённых нелокальными эффектами (нелинейные эффекты типа вынужденного рассеяния Бриллюэна).

Простая двуслойная ANN способна обработать 100 000 спектров за 1.2 с, в то время как метод нелинейной регрессии требует примерно 3 ч для аналогичного объёма данных. Ошибки определения BFS были сопоставимы с ошибками кривой Лоренца при обучении на чистых синтетических данных, но при добавлении шума производительность ANN была значительно выше [20].

Одно из ограничений простых ANN – требование фиксированного размера входного вектора. Для решения этой проблемы используется линейная интерполяция спектров для приведения всех входных данных к одинаковому количеству частотных точек.

Свёрточные нейронные сети (CNN – Convolutional Neural Networks) представляют собой специализированный класс глубоких нейросетей, которые автоматически извлекают иерархические признаки из входных данных. Архитектура CNN основана на операции свёртки – математической операции, которая применяет небольшие весовые матрицы (ядра или фильтры) к локальным участкам входных данных. Различные размерности входных данных требуют различных подходов: одномерные свёртки (1D CNN) применяются к временным рядам и спектральным профилям, тогда как двумерные свёртки (2D CNN) работают с изображениями и спектрограммами. Ниже представлено систематическое описание обеих архитектур с полным математическим аппаратом и приложениями к обработке спектральных данных, которые имеют прямое отношение к оптической обработке сигналов.

Одномерные свёрточные нейронные сети (1D CNN) представляют собой специализированный класс архитектур глубокого обучения, предназначенный для обработки последовательных данных, таких как временные ряды, сигналы, спектральные профили и другие одномерные последовательности. В отличие от классических двумерных CNN, используемых в компьютерном зрении, 1D CNN применяет свёрточные операции вдоль единственного измерения, что делает их идеальным инструментом для анализа сигналов в оптике и спектроскопии.

Основная операция, на которой базируется 1D CNN, – это одномерная свёртка. Математически свёртка представляет собой фильтрующую операцию, которая

обнаруживает сходства между фильтром и входными данными. Для входного сигнала $x[n]$ и ядра свёртки $w[k]$ (фильтра) выходной сигнал определяется формулой [21]

$$y[m] = \sum_{k=0}^{K-1} w[k] \cdot x[m-k] + b, \quad (25)$$

где

- $x[m-k]$ – входные значения со смещением;
- $w[k]$ – весовые коэффициенты ядра размером K ;
- b – смещение;
- m – текущая позиция скольжения ядра;
- $y[m]$ – выходное значение в позиции m .

Эта операция повторяется для каждой позиции m , порождая выходную последовательность.

Архитектура 1D CNN состоит из последовательных слоёв, каждый из которых выполняет специфическую функцию.

1. Входной слой принимает одномерную последовательность.
2. Свёрточные слои применяют одномерные фильтры к входным данным для извлечения локальных признаков.
3. Слои активации добавляют нелинейность.
4. Слои пулинга уменьшают длину последовательности, сохраняя важные признаки.
5. Полносвязные слои преобразуют извлечённые признаки в финальный выход.
6. Выходной слой производит предсказание.

Свёрточные нейронные сети 2D CNN базируются на дискретной двумерной свёртке, вычисляемой по формуле [22]

$$S[i, j] = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} I[i-m, j-n] \cdot K[m, n] + b, \quad (26)$$

где

- $I[i-m, j-n]$ – элементы входной матрицы;
- $K[m, n]$ – элементы ядра размером $M \times N$;
- $S[i, j]$ – элемент выходной карты признаков;
- b – смещение.

Ядро скользит по входным данным с заданным шагом (stride), и для каждой позиции вычисляется скалярное произведение перекрывающихся элементов.

Архитектура 2D CNN аналогична 1D, но работает с двумерными входными данными.

1. Входной слой принимает изображение двумерной спектрограммы сигнала обратного рассеяния.

2. Свёрточные слои применяют двумерные фильтры для извлечения пространственных признаков.

3. Слои активации вводят нелинейность.

4. Слои пулинга уменьшают пространственные размеры.

5. Полносвязные слои классифицируют или регрессируют.

Сравнение 1D CNN и 2D CNN представлено в табл. 3 [23].

Таблица 3. Сравнение 1D CNN и 2D CNN

Характеристика	1D CNN	2D CNN
Тип входных данных	Одномерные последовательности (временные ряды, спектральные профили)	Двумерные матрицы (изображения, спектрограммы)
Размер ядра	K	$K_h \times K_w$
Компьютерная сложность	Низкая	Средняя–высокая
Применение	Спектральные кривые	Анализ спектрограмм
Параллелизм	Хороший для длинных последовательностей	Хороший для регулярной пространственной структуры

6. МОДЕЛИРОВАНИЕ

Моделирование было выполнено с использованием MATLAB R2023a на имитационной модели, созданной для анализа зависимости абсолютной погрешности определения центральной частоты спектра обратного рассеяния Мандельштама-Бриллюэна при аппроксимации параболой, функциями Лоренца, Гаусса и псевдо-Фойгта, а также посредством корреляционной обработки в зависимости от SNR при различных шагах стробирования и FWHM. Моделирование проводилось при следующих физических константах:

- центральная частота бриллюэновского сдвига.....10.850 ГГц;
- число итераций для расчета СКО...1000;
- интервалы по частоте.....0.5 МГц, 1 МГц и 2 МГц;

- ширина спектральной линии.....30 МГц и 50 МГц.

Результаты моделирования представлены на рис. 2–6.

Рис. 2. Абсолютная погрешность определения центральной частоты спектра обратного рассеяния Мандельштама-Бриллюэна при аппроксимации параболой в зависимости от SNR при различных шагах стробирования и FWHM
Рис. 3. Зависимость абсолютной погрешности определения центральной частоты спектра обратного рассеяния Мандельштама-Бриллюэна от SNR при подгонке функцией Лоренца при различных параметрах стробирования и ширине спектра
Рис. 4. Зависимость абсолютной погрешности определения центральной частоты спектра от SNR при подгонке функцией Гаусса при различных шагах стробирования и FWHM
Рис. 5. Зависимость абсолютной погрешности определения центральной частоты спектра сигнала обратного рассеяния Мандельштама-Бриллюэна от SNR при подгонке функцией псевдо-Фойгта при различных параметрах стробирования и ширине спектра
Рис. 6. Абсолютная погрешность определения центральной частоты спектра обратного рассеяния Мандельштама-Бриллюэна корреляционной обработки в зависимости от SNR при различных шагах стробирования и FWHM

7. ПРИНЦИПИАЛЬНЫЕ ОГРАНИЧЕНИЯ

Принципиальные ограничения на снижение погрешности измерения центральной частоты спектра обусловлены следующими факторами [24]:

- конечная (естественная) ширина бриллюэновской линии ($\Delta\nu_B \approx 30$ МГц в стандартном одномодовом волокне при комнатной температуре), определяемая временем жизни акустических фононов и их затуханием;
- квантово-статистический предел (граница Крамера–Рао) точности оценки частоты по зашумлённому лоренцеву или фойгтову профилю при фиксированном отношении сигнал/шум;
- фундаментальный компромисс между длительностью временного окна, пространственным разрешением и точностью частотной оценки;
- нелокальные эффекты и оптическая нелинейность в протяжённых волоконных линиях при повышенных уровнях оптической мощности;
- неоднородность распределения параметров среды внутри ячейки пространственного разрешения;
- метрологические ограничения измерительного тракта (стабильность опорной частоты, линейность, динамический диапазон и собственный шум приёмно-измерительной аппаратуры).

8. ПЕРСПЕКТИВНЫЕ НАПРАВЛЕНИЯ СНИЖЕНИЯ ПОГРЕШНОСТЕЙ

Наиболее перспективные направления снижения погрешностей распределённых бриллюэновских измерительных систем включают следующие методы [25].

1. Алгоритмические методы оценки BFS:

- разработка и внедрение быстрых линеаризованных и корреляционных оценок (linear least squares по лоренцевскому профилю, Lorentzian cross-correlation с компенсацией частотного смещения);

- исследование и адаптация алгоритмов класса ESPRIT/MUSIC к реальным бриллюэновским спектрам (BGS), включая случаи с выраженной мультипиковостью (в частности, двойными пиками).

2. Методы машинного обучения и нейронные сети:

- развитие и промышленная реализация двухмерных сверточных нейронных сетей (2D CNN) для прямого извлечения частоты бриллюэновского сдвига (BFS) из «сырых» данных BOTDA/BOTDR;

- исследование физически информированных нейросетевых моделей (physics-informed networks) для обеспечения сверхвысокого пространственного разрешения и деконволюции спектров в областях с сильными пространственными градиентами.

3. Предобработка и реконструкция спектров:

- широкое внедрение методов декомпозиции исходного бриллюэновского спектра на подспектры с последующим шумоподавлением и обратным суммированием поддиапазонов;

- развитие подходов на основе дифференциального кросс-спектра (differential cross-spectrum, DCS) и анализа комплексного спектра для более точного восстановления BGS и оценки BFS.

4. Физические аспекты и аппаратная реализация:

- разработка специализированных оптических волокон и режимов возбуждения с уменьшенной шириной линии на полувысоте (FWHM) и контролируемыми бриллюэновскими параметрами;

- интеграция высокостабильных по частоте источников излучения и регулярных процедур самокалибровки частотной шкалы в состав измерительного тракта.

9. ЗАКЛЮЧЕНИЕ

Проведенный комплексный сравнительный анализ устанавливает количественные ориентиры производительности классических методов аппроксимации кривых при извлечении бриллюэновского сдвига частоты в реалистичных условиях

отношения сигнал/шум, характерных для распределенного волоконно-оптического зондирования. Основные выводы состоят в следующем.

1. Аппроксимация лоренцевского профиля с использованием алгоритма Левенберга–Марквардта остается физически обоснованным «золотым стандартом», обеспечивая среднеквадратичную ошибку порядка 0.65–0.9 МГц при $\text{SNR} \geq 11$ дБ, однако она сопровождается риском сбоев сходимости и крайне высокими вычислительными затратами.

2. Профили псевдо-Фойгта с оптимизированным параметром смешивания η повышают надежность оценки при низком SNR (3–7 дБ) за счет уменьшенной ковариации параметров модели.

3. Профили Гаусса и Фойгта обеспечивают лишь ограниченные преимущества: гауссовский профиль жертвует физически обоснованной точностью ради незначительного выигрыша во времени вычислений, тогда как профиль Фойгта увеличивает вычислительную сложность по сравнению с лоренцевской аппроксимацией Левенберга–Марквардта без сопоставимого роста точности.

4. Подходы машинного обучения демонстрируют преимущество в области низких SNR (менее 6 дБ), обеспечивая снижение погрешности по сравнению с классическими методами и устраняя проблемы сходимости; сверточные нейронные сети особенно эффективны при наличии спектральных деформаций, обусловленных резкими градиентами деформации или температуры.

Полученные результаты формируют количественную основу для инженеров и исследователей, развертывающих распределенные бриллюэновские датчики, и позволяют обоснованно выбирать компромиссы между точностью, вычислительной эффективностью, надежностью и метрологической прозрачностью. Представленная сравнительная база закладывает фундамент для дальнейшего развития методологий обработки сигналов в волоконно-оптическом зондировании в направлении увеличения дальности мониторинга и снижения погрешности измерений в задачах контроля состояния распределенной инфраструктуры.

БЛАГОДАРНОСТЬ

Авторы выражают благодарность коллективу кафедры «Фотоника в телекоммуникациях» Сибирского государственного университета телекоммуникаций и информатики за ценные рекомендации, способствующие повышению научного уровня настоящей статьи.

ФИНАНСИРОВАНИЕ

Исследование проведено в рамках Государственного задания Сибирского государственного университета телекоммуникаций и информатики, утвержденного Министерством цифрового развития, связи и массовых коммуникаций РФ, соглашение № 071-03-2026-011, 29.01.2026.

СПИСОК ЛИТЕРАТУРЫ

1. *Богачков И.В., Горлов Н.И.* Приборы и техника эксперимента. 2023. № 5. С. 70. <https://doi.org/10.31857/S0032816223050063> / *Bogachkov I. V., Gorlov N. I.* Instruments and Experimental Techniques. 2023. V. 66. №. 5, P. 775. <https://doi.org/10.1134/S0020441223050068>.
2. *Bao X., Chen L.* Sensors. 2011. V. 11. P. 4152. <https://doi.org/10.3390/s110404152>.
3. *Bao X., Chen L.* Sensors. 2012. V. 12. P. 8601. <https://doi.org/10.3390/s120708601>.
4. *Dong Y.* Photonic Sensors. 2021. V. 1. №. 11. P. 69. <https://doi.org/10.1007/s13320-021-0616-7>.
5. *Soto M.A., Thévenaz L.* Optics Express. 2013. V. 21. № 25. P. 31347. <https://doi.org/10.1364/OE.21.031347>.
6. *Armstrong B.H.* Journal of Quantitative Spectroscopy and Radiative Transfer. 1967. V. 7. P. 61. [https://doi.org/10.1016/0022-4073\(67\)90057-X](https://doi.org/10.1016/0022-4073(67)90057-X).
7. *Zhang Y., Fu G., Liu Y., Bi W.* Optik. 2013. V. 124. № 8. P. 718. <https://doi.org/10.1016/j.ijleo.2012.01.018>.
8. *Hagiwara Y., Kuwatani T.* ACS Measurement Science Au. 2025. V. 5. № 4. P. 497. <https://doi.org/10.1021/acsmeasuresciau.5c00030>.
9. *Limandri S.P., Bonetto R.D., Di Rocco H.O., Trincavelli J.* Spectrochimica Acta Part B Atomic Spectroscopy. 2008. V. 63. № 9. P. 962. <https://doi.org/10.1016/j.sab.2008.06.001>.
10. *Zheng H., Fang Z., Wang Z., Lu B., Cao Y., Ye Q., Qu R., Cai, H.* Sensors. 2018. V. 18. № 2. P. 409. <https://doi.org/10.3390/s18020409>.
11. *Zhang Y., Lu Y., Chen L., Wu T.* IEEE Sensors Journal. 2021. V. 21. № 20. P. 22792. <https://doi.org/10.1109/JSEN.2021.3110205>.
12. *Кривошеев А.И., Константинов Ю.А., Барков Ф.Л., Первадчук В.П.* Приборы и техника эксперимента. 2021. №5. С. 84. <https://doi.org/10.31857/S0032816221050062>.
13. *Кривошеев А.И., Барков Ф.Л., Константинов Ю.А., Белокрылов М.Е.* Приборы и техника эксперимента. 2022. №5. С. 5. <https://doi.org/10.31857/S0032816222050275>.
14. *Farahani M.A., Guerra E.C., Colpitts B.G.* Optics Letters. 2011. V. 36. №. 21. P. 4275. <https://doi.org/10.1364/OL.36.004275>.
15. *Barkov F.L., Konstantinov Yu.A.* Instruments and Experimental Techniques. 2023. V. 66. P. 753. <https://doi.org/10.1134/S0020441223050044>.

16. Nordin N.D., Abdullah F., Zan M.S.D., Bakar A.A.A., Krivosheev A.I., Barkov F.L., Konstantinov Y. A. Sensors. 2022. V. 22. № 7. P. 2677. <https://doi.org/10.3390/s22072677>.
17. Cao L., Abedin S., Cui G., Wang X. Sensors. 2025. V. 25. № 24. P. 7442. <https://doi.org/10.3390/s25247442>.
18. Chang Y., Wu H., Zhao C., Shen L., Fu S., Tang M. Photonics Research. 2020. V. 8. № 5. P. 690. <https://doi.org/10.1364/PRJ.389970>.
19. Горлов Н.И., Богачков И.В. Приборы и техника эксперимента. 2020. № 4. С. 145. <https://doi.org/10.31857/S0032816220040278> / Gorlov N.I., Bogachkov I.V. Instruments and Experimental Techniques. 2020. V. 63. P. 591. <https://doi.org/10.1134/S0020441220040272>.
20. Qian Y., Yang G., Lian Z., Liu D. Journal of Lightwave Technology. 2024. V. 99. P. 1. <https://doi.org/10.1109/JLT.2024.3395456>.
21. Li B., Jiang N., Han X. Sensors. 2023. V. 23. № 4. P. 1764. <https://doi.org/10.3390/s23041764>.
22. Zhang W., Sun Z., Chen X., Kong Z., Jiang S., Zhang F., Wang C. Optical Fiber Technology. 2024. V. 88. P. 103986. <https://doi.org/10.1016/j.yofte.2024.103986>.
23. Wang B., Wang L., Guo N., Zhao Z., Yu C., Lu C. Optics Express. 2019. V. 27. № 3. P. 2530. <https://doi.org/10.1364/OE.27.002530>.
24. Haodi Z., Qi W. Intelligent Perception Engineering. 2025. V. 2. № 2. P. 31. <https://doi.org/10.3969/j.issn.2097-4965.2025.02.003>.
25. Xu Z., Zhao L. Sensors and Actuators A Physical. 2020. V. 303. № 16. P. 111822. <https://doi.org/10.1016/j.sna.2019.111822>.
26. Богачков И.В. Т-сomm – Телекоммуникации и транспорт. 2016. Т. 10. № 11. С. 40.
27. Богачков И. В., Горлов Н. И. Вестник СибГУТИ. 2017. Вып. 1 (37). С. 75.
28. Богачков И. В. Т-сomm – Телекоммуникации и транспорт. 2019. Т. 13. №. 1. С. 60. <https://doi.org/10.24411/2072-8735-2018-10216>.
29. Богачков И. В., Горлов Н. И. Телекоммуникации. 2019. № 5. С. 21.
30. Богачков И.В. Т-сomm – Телекоммуникации и транспорт. 2019. Т. 13. № 7. С. 60. <https://doi.org/10.24411/2072-8735-2018-10292>.
31. Bogachkov I.V. T-comm. 2020. V. 14. № 8. P. 47. <https://doi.org/10.36724/2072-8735-2020-14-8-47-52>
32. Bogachkov I.V., Gorlov N.I. Systems of Signal Synchronization, Generating and Processing in Telecommunications (SINKHROINFO-2020) Proceedings. Kaliningrad. 2020. P. 1. <https://doi.org/10.1109/SYNCHROINFO49631.2020.9166114>.
33. Gorlov N.I., Bogachkov I.V. Systems of Signal Synchronization, Generating and Processing in Telecommunications (SINKHROINFO-2020) Proceedings. Kaliningrad. 2020. P. 1. <https://doi.org/10.1109/SYNCHROINFO49631.2020.9166063>.
34. Богачков И.В. Приборы и техника эксперимента. 2023. № 5. С. 64. <https://doi.org/10.31857/S0032816223050051> / Bogachkov I.V. Instruments and

Experimental Techniques, 2023. V. 66. N. 5, P. 769.
<https://doi.org/10.1134/S0020441223050056>.

ПОДПИСИ К РИСУНКАМ

- Рис. 1.** Пример BOTDR-рефлектограммы распределения спектра РМБ вдоль световода
- Рис. 2.** Абсолютная погрешность определения центральной частоты спектра обратного рассеяния Мандельштама-Бриллюэна при аппроксимации параболой в зависимости от SNR при различных шагах стробирования и FWHM
- Рис. 3.** Зависимость абсолютной погрешности определения центральной частоты спектра обратного рассеяния Мандельштама-Бриллюэна от SNR при подгонке функцией Лоренца при различных параметрах стробирования и ширине спектра
- Рис. 4.** Зависимость абсолютной погрешности определения центральной частоты спектра от SNR при подгонке функцией Гаусса при различных шагах стробирования и FWHM
- Рис. 5.** Зависимость абсолютной погрешности определения центральной частоты спектра сигнала обратного рассеяния Мандельштама-Бриллюэна от SNR при подгонке функцией псевдо-Фойгта при различных параметрах стробирования и ширине спектра
- Рис. 6.** Абсолютная погрешность определения центральной частоты спектра обратного рассеяния Мандельштама-Бриллюэна корреляционной обработки в зависимости от SNR при различных шагах стробирования и FWHM




Рис. 1.




Рис. 2.




Рис. 3.




Рис. 4.




Рис. 5.




Рис. 6.