

УДК 004.8 ГРНТИ 47.49.39

*Кришталь Кирилл Евгеньевич Самарский национальный исследовательский университет имени академика С.П. Королёва, Институт информатики и кибернетики 443086, Россия, г. Самара, Московское шоссе, 34 E-mail: [kristal.k.e@inbox.ru](mailto:kristal.k.e@inbox.ru)*

## **СРАВНИТЕЛЬНЫЙ АНАЛИЗ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ И НЕЙРОСЕТЕЙ ДЛЯ ДЕТЕКТИРОВАНИЯ ТРАНСПОРТНЫХ СРЕДСТВ НА ДАННЫХ КОГЕРЕНТНОЙ РЕФЛЕКТОМЕТРИИ**

Аннотация. Работа посвящена исследованию и сравнению различных алгоритмов машинного обучения и нейросетей, применяемых для задач детектирования транспортных средств на данных когерентной оптической рефлектометрии (COTDR). Представлена формализация задачи в виде бинарной классификации на основе признаков, извлечённых из предварительно обработанных рефлектограмм. Проведено обучение и тестирование моделей: наивный байесовский классификатор, метод опорных векторов, случайный лес, сверточная нейронная сеть (CNN) и рекуррентная сеть на основе LSTM. Приведены метрики оценки (точность, полнота, F1-мера) и выполнен сравнительный анализ. Работа демонстрирует эффективность глубоких архитектур и делает акцент на выборе оптимального окна признаков и архитектуры модели.

Ключевые слова: когерентная рефлектометрия, машинное обучение, нейронные сети, детектирование, виброакустика, бинарная классификация.

Введение

Развитие технологий распределённого мониторинга стимулирует интерес к применению когерентной оптической рефлектометрии (COTDR) в задачах распознавания и слежения за транспортными средствами. Преимущество COTDR заключается в возможности получения пространственно-временных карт вибраций вдоль протяжённого оптического канала. Однако интерпретация таких

данных требует применения методов машинного обучения, способных выявлять закономерности и шаблоны в массиве отражённых сигналов.

Целью данной работы является разработка и сравнение эффективности различных алгоритмов классификации транспортных событий на основе признаков, извлечённых из рефлектограмм. Исследование охватывает как классические методы машинного обучения, так и современные нейросетевые архитектуры.

### Введение

Развитие технологий распределенного мониторинга открывает новые горизонты в использовании когерентной оптической рефлектометрии (COTDR) для наблюдения за внешними воздействиями вдоль волоконно-оптических линий связи. Одним из перспективных направлений является детектирование транспортных средств, воздействующих на кабельные линии в процессе своего движения. Пространственно-временные карты вибраций, получаемые с помощью COTDR, содержат богатую информацию, однако интерпретация этих данных требует применения эффективных алгоритмов машинного обучения.

Целью настоящего исследования является разработка, обучение и сравнение моделей классификации транспортных событий на основе признаков, извлечённых из сигналов COTDR. Особое внимание уделяется сравнению классических методов машинного обучения и современных нейросетевых архитектур.

### Материалы и методы



Рисунок 1. Внешний вид и схема работы когерентного рефлектометра «Дунай».

Экспериментальная часть исследования была выполнена на основе данных, полученных с когерентного рефлектометра "Дунай-6". Устройство обеспечивает регистрацию сигналов отражения вдоль оптического волокна с временным разрешением порядка микросекунд и пространственным разрешением до нескольких метров. Все данные сохранялись в форматах RTD и HDF5 и включали как заголовки с метаданной.

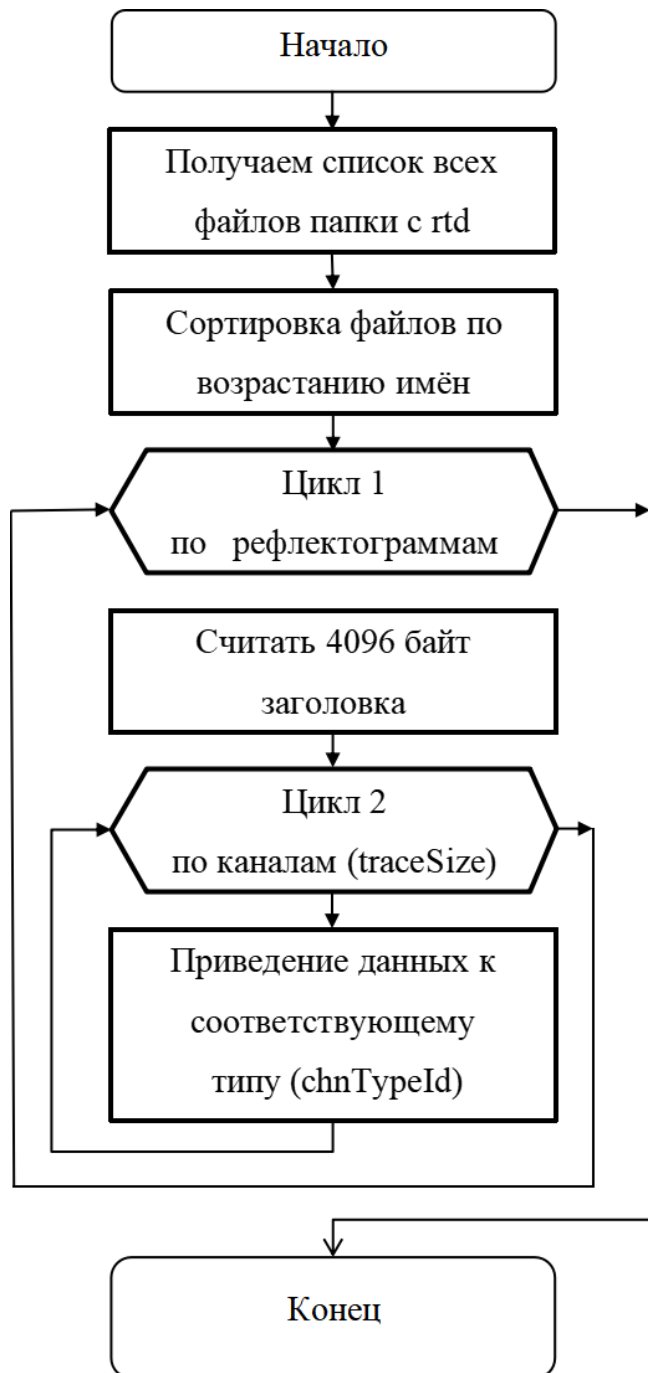


Рисунок 2. Структура рефлектограмм в формате RTD. (размер окна, количество трасс и каналов), так и массивы необработанных значений.

Предобработка данных включала следующие шаги:

- Нормализация и стандартизация: Применялось Z-преобразование для каждого канала по строкам (вдоль времени) и по столбцам (вдоль расстояния).




Рисунок 3. Исходные и нормализованные рефлектограммы.

Применялось Z-преобразование для каждого канала по строкам (вдоль времени) и по столбцам (вдоль расстояния) с целью устранения глобальных сдвигов и различий в масштабах.

- Частотная фильтрация: Использовалось БПФ для подавления высокочастотных шумов и артефактов.

Рисунок 4. Спектральная фильтрация: удаление шумов выше 35-й гармоники. Использовалось БПФ для подавления высокочастотных шумов и артефактов. В качестве предела применялась 35-я гармоника, определённая эмпирически на основе анализа спектров.

- Линейная фильтрация: Ядро  $9 \times 1$  усиливало горизонтальные компоненты на рефлектограммах.




Рисунок 5. Результат линейной фильтрации и оператора Собеля. Ядро  $9 \times 1$  усиливало горизонтальные компоненты на рефлектограммах и устраняло вертикальные шумы, возникающие при рассеянии.

- Пространственные операторы: Оператор Собеля применялся к каждой рефлектограмме, усиливая наклонные границы, соответствующие движущимся объектам. Также тестировались детекторы Кэнни, однако они показали переизбыточную чувствительность.
- Скелетизация: Алгоритм Чжана-Суэна позволял преобразовать бинаризованные изображения в однопиксельные линии.




Рисунок 6. Скелетизация и аппроксимация траекторий. Алгоритм Чжана-Суэна позволял преобразовать бинаризованные изображения в однопиксельные линии, облегчая дальнейшее извлечение направлений.

- Линейная аппроксимация и анализ направления: Каждая выделенная линия аппроксимировалась прямой с использованием метода наименьших квадратов. Из аппроксимации извлекались параметры: угол наклона, длина и координаты начала и конца, что позволило отфильтровать неподвижные объекты.
- Формирование целевых меток: Центры горизонтальных отрезков, соответствующих движущимся объектам, использовались как маркеры классов.

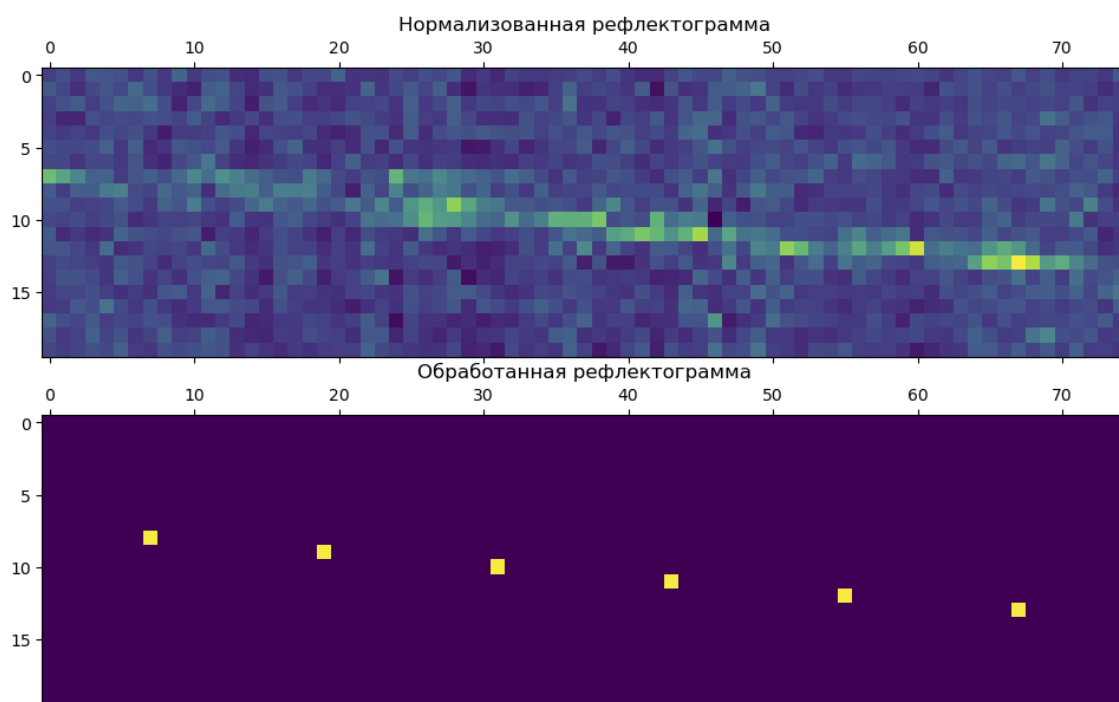


Рисунок 7. Выделение координат транспортных средств. Центры горизонтальных отрезков, соответствующих движущимся объектам, использовались как маркеры классов (0/1).

Обучающий датасет формировался путём скользящего окна с размерами 51, 101, 151, 201. Каждое окно включало в себя нормализованные признаки:

статистики (среднее, максимум, минимум, стандартное отклонение), частотные признаки (энергия спектра, доминирующая гармоника), угловые характеристики. Классы были сбалансированы методом under-sampling, что позволило минимизировать перекося в сторону фона (отсутствия транспорта).

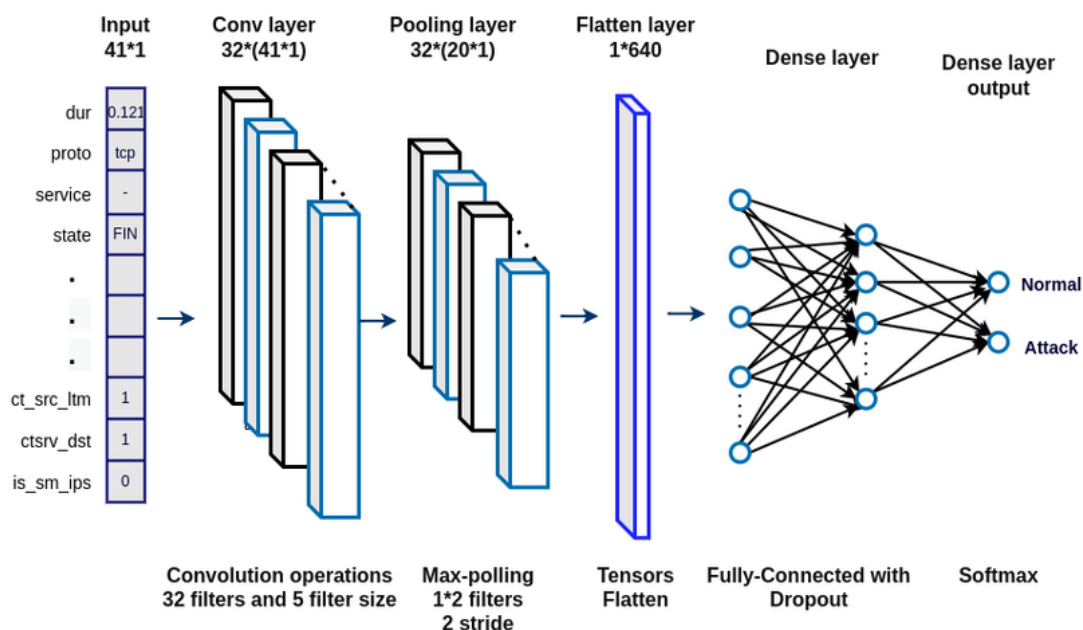


Рисунок 8. Архитектура сверточной нейросети.




Рисунок 9. Архитектура LSTM-сети.

Обучение моделей:

- Наивный байесовский классификатор (NB): реализован через `scikit-learn`. Прост в реализации и интерпретации, не требует подбора гиперпараметров.

- Метод опорных векторов (SVM): использовалась RBF-ядро. Подбор гиперпараметров проводился через GridSearchCV.
- Случайный лес (RF): обучался с 100 деревьями, глубиной до 10. Строилась важность признаков.
- Сверточная нейросеть (CNN): включала три Conv1D слоя, два слоя MaxPooling, Dropout-слои, а также BatchNormalization. Активаторы — ReLU.
- Рекуррентная нейросеть (LSTM): два слоя по 100 ячеек, выходной слой Dense, dropout и BatchNorm. Использовалась функция активации sigmoid.

Все модели обучались на GPU (NVIDIA RTX 3080), с использованием библиотек TensorFlow 2.10 и Keras. Обучение производилось в течение 20 эпох, batch size = 512.

Оценка моделей проводилась с помощью метрик:

- Accuracy (доля верных предсказаний);
- Precision (точность);
- Recall (полнота);
- F1-мера (сбалансированное качество);
- ROC-AUC (площадь под ROC-кривой).

Также проводилась валидация на отложенной выборке, а для нейросетей строились кривые обучения. Оценивалась устойчивость к шумам и способность к обобщению. Модели сравнивались по времени инференса: классические — <10 мс, нейросети — до 100 мс, что укладывается в допустимые пределы систем мониторинга (до 1 с).

Таким образом, раздел «Материалы и методы» охватывает полный цикл: от сбора и форматирования данных до построения, настройки и тестирования моделей классификации транспортных событий.

Результаты экспериментов

Дополнительно были построены кривые Precision-Recall и ROC, которые подтвердили высокий уровень обобщающей способности LSTM и CNN моделей по сравнению с классическими методами. У LSTM-архитектуры была наибольшая площадь под ROC-кривой ( $AUC > 0.9$ ), что указывает на её надёжность в условиях шумных и переменных входных данных.

Также была проведена валидация моделей на отложенной выборке, не участвовавшей в обучении, с целью оценки обобщающей способности алгоритмов. Результаты подтвердили, что нейросетевые архитектуры сохраняют высокую точность при неизменных параметрах, в то время как простые модели теряли эффективность, особенно в условиях смещённого распределения классов. Для оценки влияния размера обучающей выборки были построены кривые обучения. Они показали, что для классических моделей точность стабилизируется при достижении ~5000 примеров, тогда как для нейросетей требуется как минимум 8000 обучающих окон для выхода на плато по точности. Это подтверждает необходимость большего объёма данных при использовании глубоких моделей, но и их преимущество при наличии таких данных.

Также была проведена оценка времени обучения и инференса моделей. Наивный Байес и случайный лес показали высокую скорость, подходящую для задач встраиваемых систем. Однако нейросети обеспечили значительно более точные результаты при чуть большем времени инференса, что допустимо в контексте систем мониторинга с квазиреальным временем реакции (до 1 секунды).

Была проанализирована важность признаков для моделей случайного леса и SVM. Выяснилось, что наиболее значимыми являются признаки, описывающие амплитуду и угловой наклон центральных фрагментов окна, что коррелирует с положением и направлением движения объекта на рефлектограмме. Это подтверждает физическую обоснованность выборки признаков и усиливает доверие к модели.

В целом, результаты экспериментов демонстрируют, что даже при использовании относительно простых архитектур можно добиться высоких показателей качества, если предварительная обработка данных и инженерия признаков выполнены на должном уровне.

#### Выводы

Проведённый сравнительный анализ продемонстрировал преимущества использования нейросетевых подходов для детектирования транспортных средств на данных COTDR. LSTM-сеть показала наивысшие показатели качества, особенно при оптимальном размере окна. Методология, представленная в работе, может быть расширена на многоклассовую классификацию и использована в системах охраны и интеллектуального транспорта. Дальнейшие исследования планируется направить на реализацию онлайн-обработки и оптимизацию производительности.

## СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1 Когерентный фазочувствительный рефлектометр с дифференциальной фазовой модуляцией зондирующих импульсов / А. Э. Алексеев, В. С. Вдовенко, Б. Г. Горшков, В. Т. Потапов, И. А. Сергачев, Д. Е. Симикин // Волоконно-оптические датчики. Квантовая электроника. – 2014. – Т. 44, № 10. – С. 965 – 969.

2 Когерентный рефлектометр с полупроводниковым источником излучения / М. А. Слепцов, В.Н. Трещиков, О.Е. Наний, А.А. Сусьян // Тезисы докладов Всероссийской Конференции по Волоконной Оптике, Спецвыпуск журнала Фотон-экспресс. – 2016. – Т.12, №5. – С. 92–93.

3 Когерентный оптический рефлектометр. концепция создания прибора / Е.Т. Нестерев, М.А. Слепцов, В.Н. Трещиков, О.Е. Наний, А.А. Сусьян // Телекоммуникации и транспорт (Т-Comm). – 2016. – Т.12, №4. – С. 51–54.

4 Увеличение дальности работы когерентного рефлектометра при использовании волокна с интегрированными решётками брэгга / А.И. Кузьменков, О.Е. Наний, С.П. Никитин, Ф.И. Улановский, М.Ю. Вяткин, С.М. Попов, В.А. Конышев, В.Н. Трещиков, Ю.К. Чаморовский // Оптическая рефлектометрия 2016. – 2016. – Т.12, №3. – С. 101-104.

5 Волоконно-оптическая система мониторинга протяжённых объектов (нефтепроводов) на основе когерентного рефлектометра / М.А. Слепцов, В.Н. Трещиков, О.Е. Наний, А.А. Сусьян // Телекоммуникации и транспорт (Т-Comm). – 2014. – Т.11, №8. – С. 51–54

6 Пат. 2477838 Российская Федерация МПК G01D 5/353 В.С когерентный оптический рефлектометр для обнаружения вибрационных воздействий / Вдовенко В.С, Горшков Б.Г, Заирный Д.В, Заирный М.В; Общество с ограниченной ответственностью "ПетроФайбер заявл. 28.10.2011; опубл. 20.03.2011, Бюл № 8 – 7 с.