

Анализ и Распознавание Транспортных Шумов с Использованием Нейросетевого Подхода

Копылова О.А.¹, Хайретдинов М.С.¹

¹ *Институт вычислительной математики и математической геофизики СО РАН, пр. акад. Лаврентьева, д. 6, г. Новосибирск, 630090, Россия.*

oksana@opg.sscs.ru, marat@opg.sscs.ru

Аннотация. В работе рассматривается задача распознавания движущихся транспортных средств по записям сейсмических колебаний в условиях реальной фоновой обстановки. Целью работы является разработка методов и алгоритмов распознавания, предназначенных для использования в сейсмоакустических системах наблюдения в режиме реального времени. Рассматриваются различные виды железнодорожного, тяжелого колесного, гусеничного транспорта. Решение задачи основано на использовании сверточной нейронной сети с учетом спектральных характеристик транспортных колебаний. Отдельно рассматриваются вопросы распознавания в условиях меняющегося уровня внешних шумов и пространственного положения транспорта по отношению к пунктам регистрации колебаний. Приводятся результаты работы алгоритма распознавания на данных полевых экспериментов.

Ключевые слова: распознавание транспортных вибраций, сверточная нейронная сеть, сейсмические и акустические колебания, полевой эксперимент

1 Введение

Одной из основных задач геоэкологического мониторинга окружающей среды является выявление источников загрязняющего шума в условиях города. В такой постановке решение задачи связано с задачей распознавания источников транспортных колебаний, возникающих в земле и атмосфере. С целью формирования информативной системы признаков в работе приводятся результаты спектрального-временного анализа колебаний от тяжелых видов транспорта – железнодорожного, тяжелого колесного и гусеничного видов транспорта. Такие колебания распространяются в виде сейсмических в земле и акустических в атмосфере.

Решение задачи распознавания движущихся транспортных средств по записям сейсмических сигналов может быть построено на сравнении текущего вектора значений информативных признаков для различных источников с их эталонами, полученными статистическими методами [1, 2]. В работе [3] распознавание объектов классов «пешеход» и «автомобиль» проводилось с помощью вероятностной нейронной сети. Авторы статьи [4] предложили решение проблемы распознавания людей, животных и вездеходов по данным сейсмических и инфракрасных датчиков на основе бинарной классификации с использованием метода опорных векторов. В работе [5] рассматривалось распознавание техногенных шумов с использованием нейронной сети прямого распространения и метода k-ближайших соседей. В статье [6] рассматривается проблема распознавания классов «человек», «транспортное средство» и «животное» по данным акустических записей и классов «человек», «транспортное средство» и «группа людей» по данным вибрационных записей с помощью метода опорных векторов (SVM). На вход алгоритма классификации подавались необработанные данные вибрационных колебаний и мел-кепстральные коэффициенты (MFCC) акустических колебаний. В работе [7] для классификации колесных и гусеничных транспортных средств по сейсмическому сигналу предлагается сверточная нейронная сеть (CNN). В качестве информативных признаков

используются частотно-кепстральные коэффициенты в логарифмическом масштабе. В работе [8] авторы предлагают решение проблемы распознавания движущихся пешеходов, колесных и гусеничных транспортных средств по сейсмическим данным на основе блока SE-Inception. Авторы статьи [9] рассматривают задачу классификации объектов классов «колесный трактор» и «автобус» по частотно-временным коэффициентам на основе эмпирического вейвлет-преобразования (EWT) с использованием алгоритмов SVM и KNN. В работе [10] распознавание объектов классов «группа людей», «колесная» и «гусеничная техника» основывалось на сверточной нейронной сети. В работе [11] для распознавания пешеходов, сигналов транспортных средств и шумов окружающей среды по сейсмическим колебаниям также основой служил алгоритм SVM. SVM применялся для распознавания поездов, людей, слонов, оленей, электрического шума по сейсмическим колебаниям в [12]. В статье [13] для распознавания движущихся объектов таких, как беспилотники, гусеничные машины, колесные машины, люди и животные, предложено использовать новый метод CO-SDL (Compression Observation-Seismic DL). Авторами [14] для распознавания колесной и гусеничной техники было предложено использовать метод сжатия CS и одномерную сверточную нейронную сеть 1-D CNN. В работе [15] для распознавания движущихся транспортных средств использовалась сверточная нейронная сеть с двунаправленной долговременной кратковременной памятью (1D CNN-BiLSTM). Для классификации движущегося транспорта категориям «большие», «средние» и «малые» авторы работы [16] использовали логистическую регрессию, метод опорных векторов и наивный байесовский алгоритм. Для распознавания движущихся транспортных средств по данным сейсмических колебаний авторы [17] предлагают свое решение, основанное на использовании сверточной нейронной сети и глубокого двунаправленного LSTM (Long short-term memory) – CNN-DBiLSTM.

Отличительная особенность настоящей работы увязывается с вопросами обнаружения и распознавания на предельных расстояниях, превосходящих известные в условиях воздействия внешних шумов. При этом алгоритмы и программы ориентированы на обработку данных в режиме реального времени.

2 Постановка задачи

2.1 Общая постановка задачи

В качестве критерия распознавания используется вероятность правильного распознавания как функция трех составляющих:

$$P = \psi(F, N, A) \quad (1)$$

где P – вероятность правильного распознавания, F – вектор признаков, N – составляющая внешнего шума, A – алгоритм распознавания.

Вектор признаков F формируется из значений спектральных функций $F(x_k, t)$ регистрируемых транспортных колебаний, представляемых в виде модели:

$$x_k(t_i) = A_x(k)h_k L \left[\cos(\omega_0(t_i - \Delta t_k) + \varphi_x(k)) + n_k(t_i) \right] \quad (2)$$

где ω_0 – преобладающая в спектре колебаний частота вращения двигателя; $\varphi_x(k)$ – фаза ее в k -ой точке регистрации; t_i меняется в пределах от t_{0i} до $t_{0i} + T$, где T – длительность сигнала, а t_{0i} соответствует моменту появления полезного колебания, $n_k(t)$ – широкополосная шумовая составляющая, отражающая взаимодействие источника со средой в процессе его движения, и вклад внешнего шума; A_x – амплитуда колебания на k -ом датчике; h_k – чувствительность датчика; L – оператор фильтрации сигнала.

С учетом варибельности основных составляющих параметров в (2), обусловленных меняющимися характеристиками режимов движения транспортных средств по скорости и их положения в пространстве, задача распознавания приобретает динамический характер и ее решение распадается на этапы обнаружения транспортных колебаний на фоне внешних шумов, выделения информативных признаков, выбор непосредственно алгоритма распознавания и конечный этап, связанный с оценением эффективности работы комплекса алгоритмов обработки на экспериментальных данных. Авторами рассмотрены все этапы решения задачи распознавания.

Предлагаемые авторами алгоритмы обнаружения и результаты оценивания их эффективности по критерию дальности обнаружения по отношению к некоторым видам транспортных средств представлены в [18]. Остановимся на следующем этапе.

2.2 Выделение информативных признаков

Решение задачи выделения информативных признаков осуществляется на основе использования секционированного спектрального анализа на основе дискретного преобразования Фурье, позволяющего проследить динамику изменения спектра во времени, обусловленную меняющимися режимами движения транспортных средств во времени и пространстве:

$$F(k, l) = \sum_{n=0}^{N-1} x_i(t_n) \exp(-i \frac{2\pi n k}{N}), l = 1, \dots, L \quad (3)$$

Здесь L - количество секций длительностью $\Delta T = N \cdot \Delta t$ каждая, на которые секционируется искомый сигнал $x(t)$, Δt - интервал выборки дискретных значений сигнала.

Следствием меняющегося пространственного положения транспорта является ярко выраженный уровень вариаций регистрируемых транспортных колебаний в системе сейсмоакустического наблюдения. В связи с этим процедура нормировки исходных данных по уровню является необходимой предобработкой для формирования спектральных признаков, инвариантных к расстоянию и уровню внешних шумов. Преобразование исходных данных результата спектрального анализа выполняется так, чтобы все амплитудные значения бинов (отсчетов) лежали в диапазоне $[0;1]$ в соответствие: $x_i = x_i / \max(x)$, где x_i - i -ое значение бина спектральной функции, x - вектор значений бинов спектральной функции.

Для повышения помехоустойчивости спектральных признаков применяется полосовая цифровая фильтрация спектра транспортных колебаний из спектров внешних шумов согласно заданию оператора L в (2). В качестве его выбрана передаточная функция цифрового фильтра Баттерворта 4-го порядка:

$$L(\omega) = \frac{1}{\sqrt{1 + (\frac{\omega}{\omega_0})^{2n}}}, \quad (4)$$

где ω_0 - граничная частота, n - порядок фильтра.

3. Нейросетевой алгоритм распознавания транспортных источников

Набор исходных данных для распознавания представляется в виде набора матриц с размером $M \times N$, где M - длительность секции в сек (3), в пределах которого осуществляется анализ, N - количество бинов спектральной функции.

Распределение образцов по классам представлено ниже (Рис. 1). Классы кодировались следующим образом: 0 - электропоезд, 1 - грузовой поезд, 2 - гусеничный транспорт, 3 -тяжелый колесный транспорт.

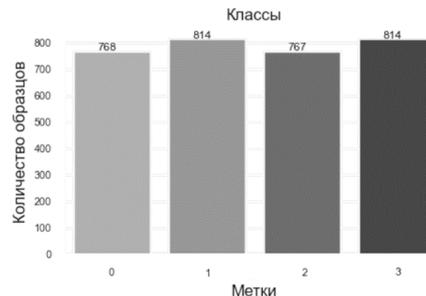


Рис. 1. Распределение набора данных по классам

Полученный набор из экспериментальных данных был перемешан случайным образом и разделен на тренировочную и тестовую выборки в соотношении 3:1. Такое разделение обеспечивает достаточное количество экземпляров в обучающей и тестовой выборках для обучения модели и ее тестирования. Нейронная сеть состоит из двух двумерных сверточных слоев (Conv2D), выпрямляющего слоя (Flatten), слоя подвыборки для снижения размерности (MaxPooling2D), полносвязного слоя классификатора (Dense) и выходного полносвязного слоя

(Dense – output layer). Основные компоненты предлагаемой нейронной сети представлены на Рис. 2 (а).

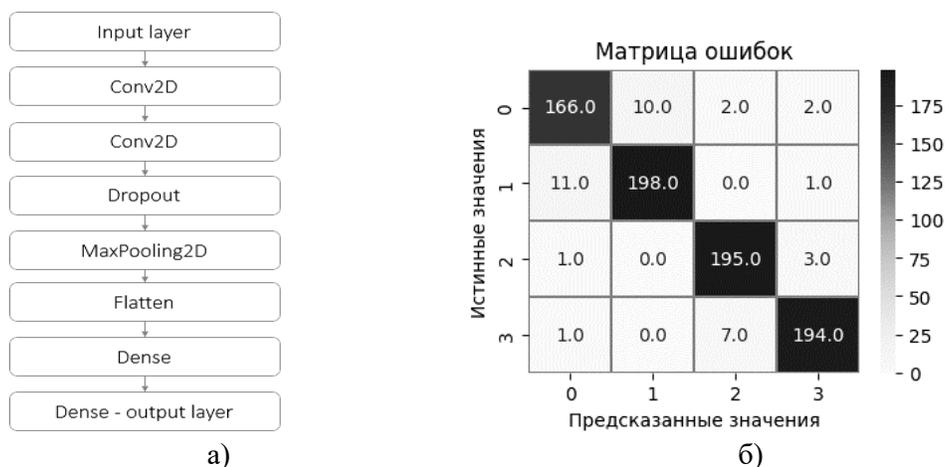


Рис. 2. а) Структурная схема нейронной сети б) Матрица ошибок классификации

В качестве функции потерь использовалась категориальная кроссэнтропия, которая описывает, насколько близко предсказанное распределение к истинному распределению. В качестве алгоритма оптимизации подбора весов и повышения скорости обучения используется оптимизатор «Adam» [19], который вычисляет индивидуальные адаптивные скорости обучения для различных параметров из оценок первого и второго моментов градиентов.

Проверка точности работы классификатора, обученного на тестовой выборке, производилась на данных, не участвовавших в процессе обучения нейронной сети, что обеспечивает оценку обобщающей способности модели к обучению и исключает влияние эффекта переобучения на значение показателя точности.

Процент правильного распознавания рассчитывается как отношение числа правильно классифицированных образцов к числу всех образцов. На тестовой выборке такой показатель составил 95%. Для достижения данного результата потребовалось 21 эпоха. Ниже на рисунке (Рис. 2 (б)) представлена матрица ошибок, показывающая распределение случаев правильного и ошибочного распознавания по классам.

4. Методика проведения экспериментов

Для получения статистики записей шумов проводились эксперименты по записи сейсмических и акустических колебаний, порождаемых различными видами движущейся транспортной техники – железнодорожной, автомобильной, гусеничной.

Был проведён ряд натуральных экспериментов по записи и обнаружению транспортных колебаний на расстояниях до 3-х километров. Регистрация сейсмоакустического волнового поля от транспортных средств осуществлялась с помощью трёхкомпонентных сейсмических датчиков GS-3[20] и СК1-П [21], а также акустических датчиков ПДС-7 [22]. Запись колебаний осуществлялась с помощью регистраторов серии «Байкал-АСН», которые представляют собой 3-канальные автономные сейсмические станции расширенного частотного диапазона с внутренним модулем GPS, каналом USB 2.0 для связи с компьютером и внутренней памятью на основе FLASH- или SD-карт [23].

С целью исследования особенностей сейсмических и акустических сигналов от различного вида железнодорожного и автомобильного движущегося транспорта вблизи расположения оживленной автомобильной дороги и железнодорожных путей были проведены эксперименты по записи колебаний. Дополнительно была проведена серия экспериментов по записи сейсмических и акустических колебаний от тяжелого колесного и гусеничного транспорта, направленная на получение записей данных для уточнения характеристик каждого из них в отдельности. Эксперименты проводились утреннее, дневное, вечернее и ночное время суток в разные сезоны года. На Рис. 3 в качестве примера приведены карты расстановок

аппаратуры некоторых из проведенных экспериментов. Точные значения геометрических параметров расстановки датчиков в каждом эксперименте определялись по GPS.

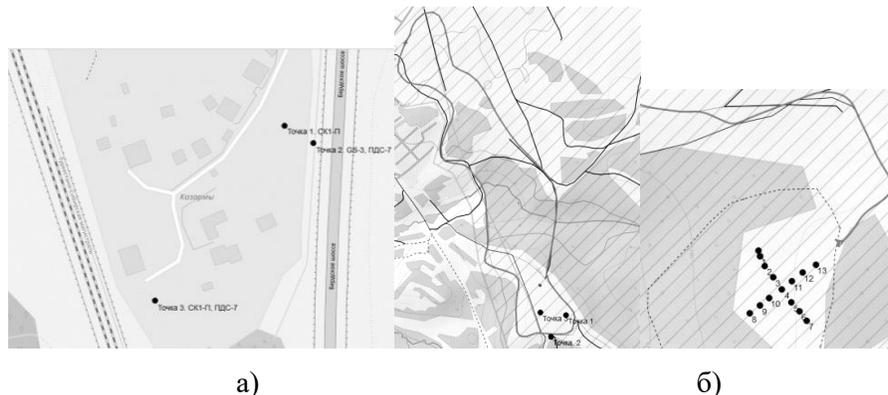


Рис. 3. Схема эксперимента по записи сейсмоакустических колебаний а) от железнодорожного и автомобильного транспорта б) от тяжелого колесного и гусеничного транспорта

Полученные данные являются материалом для предварительного анализа и выделения информативных признаков, а также обучения и тестирования нейронной сети.

Ниже на Рис. 4 приведен пример нормированных спектрально-временных функций, полученных для различного вида транспорта. Видно, что спектр колебаний от тяжелого транспорта располагается в области низких и инфранизких частот. Для некоторых из рассматриваемых видов транспорта характерно наличие узкополосной составляющей в спектре сигнала.

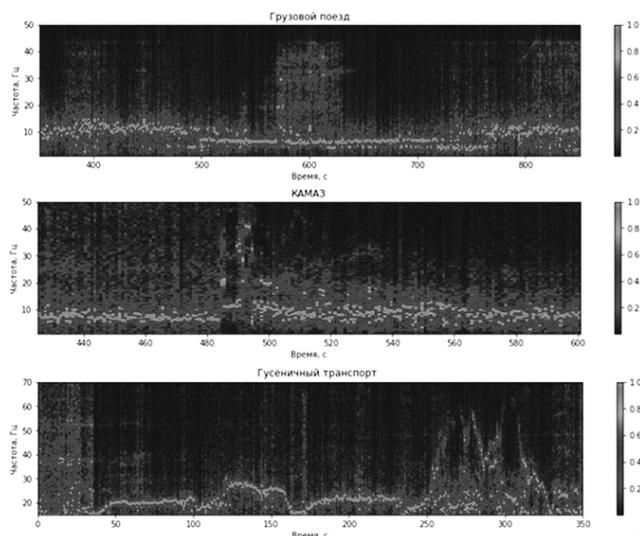


Рис. 4. Нормированная СВФ записей сейсмических колебаний от движущегося транспорта

5 Заключение

В работе предложен и реализован алгоритм распознавания транспортных объектов по сейсмическим колебаниям на основе сверточной нейронной сети. В качестве входных данных были использованы спектрально-временные признаки сейсмических колебаний, возникающих при движении тяжелых видов транспорта средств таких, как электропоезд, грузовой поезд, тяжелый колесный и гусеничный виды транспорта. Алгоритм был протестирован на данных полевых экспериментов, собранных в различной местности и в разные сезоны года. Достигнут результат правильного распознавания видов транспорта около 95%. Алгоритм работает на данных, полученных при различных дальностях движения транспорта, начиная от 700 метров и

выше в зависимости от типа транспорта. Полученные при этом результаты одновременно по дальности обнаружения при той же точности распознавания превосходят ранее полученные другими авторами.

6 Благодарности

Работа выполнена в рамках госзадания FWNМ–2022–0004.

Литература

- [1] Левковская Т.В., Козлов Э.В., Мурашко Н.И. Обработка сейсмических сигналов в интеллектуальных системах пассивной локации. Информатика. 2010;(3(27)) с. 89-96
- [2] Хайретдинов М.С., Авроров С.А. Обнаружение и распознавание взрывных источников. // Вестник НЯЦ РК. — 2012. — №12. — с.17–24.
- [3] Алямкин С.А. Классификация объектов в сейсмической системе обнаружения с учетом параметров их движения. Автореф. дис. кан. тех. наук. – Новосибирск.: 2014. – 21с.
- [4] X. Jin, S. Sarkar, A. Ray, S. Gupta and T. Damarla, "Target Detection and Classification Using Seismic and PIR Sensors," in IEEE Sensors Journal, vol. 12, no. 6, pp. 1709-1718, June 2012, doi: 10.1109/JSEN.2011.2177257.
- [5] P. Khunarsal, C. Lursinsap, and T. Raicharoen, "Very short time environmental sound classification based on spectrogram pattern matching", Information Sciences, vol. 243, no. Complete, 2013, pp. 57–74, doi:10.1016/j.ins.2013.04.014.
- [6] S. E. Küçükbay, M. Sert and A. Yazici, "Use of Acoustic and Vibration Sensor Data to Detect Objects in Surveillance Wireless Sensor Networks," 2017 21st International Conference on Control Systems and Computer Science (CSCS), Bucharest, Romania, 2017, pp. 207-212, doi: 10.1109/CSCS.2017.35.
- [7] G. Jin, B. Ye, Y. Wu and F. Qu, "Vehicle Classification Based on Seismic Signatures Using Convolutional Neural Network," in IEEE Geoscience and Remote Sensing Letters, vol. 16, no. 4, pp. 628-632, April 2019, doi: 10.1109/LGRS.2018.2879687.
- [8] Y. Wang, X. Cheng, P. Zhou, B. Li and X. Yuan, "Convolutional Neural Network-Based Moving Ground Target Classification Using Raw Seismic Waveforms as Input," in IEEE Sensors Journal, vol. 19, no. 14, pp. 5751-5759, 15 July15, 2019, doi: 10.1109/JSEN.2019.2907051.
- [9] M. Kalra, S. Kumar and B. Das, "Seismic Signal Analysis Using Empirical Wavelet Transform for Moving Ground Target Detection and Classification," in IEEE Sensors Journal, vol. 20, no. 14, pp. 7886-7895, 15 July15, 2020, doi: 10.1109/JSEN.2020.2980857.
- [10] Y. Wang, X. Cheng, X. Li, B. Li and X. Yuan, "Powerset Fusion Network for Target Classification in Unattended Ground Sensors," in IEEE Sensors Journal, vol. 21, no. 12, pp. 13466-13473, 15 June15, 2021, doi: 10.1109/JSEN.2021.3067648.
- [11] Q. Zhou, X. Yao, C. Wang, J. Hu, P. Liu and J. Lin, "Adaptive Moving Ground-Target Detection Method Based on Seismic Signal," in IEEE Geoscience and Remote Sensing Letters, vol. 19, pp. 1-5, 2022, Art no. 2503705, doi: 10.1109/LGRS.2022.3153368.
- [12] D. S. Parihar, R. Ghosh, A. Akula, S. Kumar and H. K. Sardana, "Variational Mode Decomposition of Seismic Signals for Detection of Moving Elephants," in IEEE Transactions on Instrumentation and Measurement, vol. 71, pp. 1-8, 2022, Art no. 2510908, doi: 10.1109/TIM.2022.3178465.
- [13] K. Bin, J. Lin, X. Tong and T. Nie, "Intelligent Moving Target Recognition Based on Compressed Seismic Measurements and Deep Neural Networks," in IEEE Transactions on Geoscience and Remote Sensing, vol. 60, pp. 1-13, 2022, Art no. 5907213, doi: 10.1109/TGRS.2021.3108467.
- [14] K. Bin, J. Lin and X. Tong, "Edge Intelligence-Based Moving Target Classification Using Compressed Seismic Measurements and Convolutional Neural Networks," in IEEE Geoscience

- and Remote Sensing Letters, vol. 19, pp. 1-5, 2022, Art no. 7502105, doi: 10.1109/LGRS.2021.3055795.
- [15]S. Mohine, B. S. Bansod, R. Bhalla and A. Basra, "Acoustic Modality Based Hybrid Deep 1D CNN-BiLSTM Algorithm for Moving Vehicle Classification," in IEEE Transactions on Intelligent Transportation Systems, vol. 23, no. 9, pp. 16206-16216, Sept. 2022, doi: 10.1109/TITS.2022.3148783.
- [16]Ahmad, A.B.; Saibi, H.; Belkacem, A.N.; Tsuji, T. Vehicle Auto-Classification Using Machine Learning Algorithms Based on Seismic Fingerprinting. Computers 2022, 11, 148. <https://doi.org/10.3390/computers11100148>
- [17]Tongyu Nie, Sirui Wang, Yuqi Wang, Xunqian Tong & Feng Sun. An effective recognition of moving target seismic anomaly for security region based on deep bidirectional LSTM combined CNN. Multimedia Tools and Applications, 2023, 14p, doi: 10.1007/s11042-023-14382-5.
- [18]Добродородный В.И., Копылова О.А., Хайретдинов М.С. Обнаружение и пеленгование транспортных объектов в сейсмоакустических системах наблюдения. Вестник СибГУТИ. 2023;17(1):3-17. <https://doi.org/10.55648/1998-6920-2023-17-1-3-17>
- [19]D. Kingma and J. Ba. Adam: A Method for Stochastic Optimization. In Proc. of the Int. Conf. on Learning Representations (ICLR), 2015.
- [20]GS-20DX трехкомпонентный // ООО «Геоспейс Технолоджис Евразия». URL: <https://geospace-ufa.ru/products/geofony-odinochnye-v-korpuse/GS-20DX-trekhkomponentnyy/> (дата обращения: 10.05.2023)
- [21]Сейсмоприемник низкочастотный трехкомпонентный СК-1П. Техническое описание и инструкция по эксплуатации. Алма-Ата: НПО Геофизика. Завод Казгеофизприбор, 1977г. 12 с. [ТОО "ЭЛГЕО" <https://elgeo.kz/lfgeoph.shtml>]
- [22]Геофизические методы исследований // авт. В.К. Хмелевской, Ю.И. Горбачев, А.В. Калинин, М.Г. Попов, Н.И. Селиверстов, В.А. Шевнин. // Под редакцией Н.И. Селиверстова. Учебное пособие для геологических специальностей вузов. Петропавловск-Камчатский: изд-во КГПУ, 2004, 232 с.
- [23]Техническое описание «Байкала-АСН» // ФГБУН Федеральный исследовательский центр «Единая геофизическая служба Российской академии наук» URL: <http://www.gsras.ru/unu/uploads/files/Dataloggers/Baikal-ACN.pdf> (дата обращения: 10.05.2023)