



## К вопросу подготовки данных геоакустических наблюдений для идентификации пред- и постсейсмических аномалий

Ю. И. Сенкевич\*, М. А. Мищенко

Институт космофизических исследований и распространения радиоволн ДВО РАН,  
684034, с. Паратунка, ул. Мирная, д. 7, Россия

**Аннотация.** Предложен метод повышения качества подготовки геофизических данных на примере геоакустических наблюдений для обучения нейронных сетей в рамках решения задачи идентификации пред- и постсейсмических аномалий. Метод основан на преобразовании сигнала геоакустической эмиссии, связанной с деформационными процессами в приповерхностных породах, в трёхмерные изображения. Серия таких изображений несёт информацию о динамике характеристик сигнала. Трёхмерные изображения представляют из себя матрицы, состоящие из векторов распределения выбранных характеристик (спектральных, структурных, статистических и др.). Из серии таких изображений формируется структура — тензор данных, которая подаётся на вход нейронной сети. Из-за влияния внешних факторов (погодных, техногенных) регистрируемый геоакустический сигнал искажается. Поэтому необходимо производить очистку исходных данных. Для этого предлагается использовать нейронную сеть, которая проводит кластеризацию подготовленных изображений и удаляет выбросы в полученных кластерах. Из оставшихся изображений формируется новый тензор, который повторно подвергается очистке. Это продолжается до тех пор, пока в результате кластеризации в выходных данных обнаруживаются выбросы. Применение разработанного метода очистки тензоров на основе технологий искусственного интеллекта позволяет значительно улучшить качество подготовки данных. Подготовленные таким образом данные будут подаваться на вход другой нейронной сети с целью обнаружения общих и отличительных черт, а также закономерностей, скрытых в потоке геоакустических данных. Получаемые результаты будут полезны для исследований в области идентификации и классификации пред- и постсейсмических аномалий в сигналах геоакустической эмиссии, связанных с деформационными процессами в приповерхностных породах в сейсмоактивном регионе.

*Ключевые слова:* геоакустическая эмиссия, приповерхностные породы, динамика характеристик сигнала, кластеризация, нейронные сети, предсейсмические аномалии, постсейсмические аномалии.

Получение: 07.11.2024; Исправление: 19.11.2024; Принятие: 22.11.2024; Публикация онлайн: 28.11.2024

**Для цитирования.** Сенкевич Ю. И., Мищенко М. А. К вопросу подготовки данных геоакустических наблюдений для идентификации пред- и постсейсмических аномалий // Вестник КРАУНЦ. Физ.-мат. науки. 2024. Т. 49. № 4. С. 125-134. EDN: PHFGUU. <https://doi.org/10.26117/2079-6641-2024-49-4-125-134>.

**Финансирование.** Исследование выполнено за счет Государственного задания ИКИР ДВО РАН (рег. № темы 124012300245-2)

**Конкурирующие интересы.** Конфликтов интересов в отношении авторства и публикации нет.

**Авторский вклад и ответственность.** Авторы участвовали в написании статьи и полностью несут ответственность за предоставление окончательной версии статьи в печать.

\*Корреспонденция: ✉ E-mail: [senkevich@ikir.ru](mailto:senkevich@ikir.ru)

Контент публикуется на условиях Creative Commons Attribution 4.0 International License



© Сенкевич Ю. И., Мищенко М. А., 2024

© ИКИР ДВО РАН, 2024 (оригинал-макет, дизайн, составление)



## Question on the Preparation of Geoacoustic Observation Data for Identification of Pre- and Post-Seismic Anomalies

*Y. I. Senkevich\**, *M. A. Mishchenko*

Institute of Cosmophysical Research and Radio Wave Propagation FEB RAS,  
684034, Paratunka, Mirnaya Str., 7, Russia

**Abstract.** The paper proposes a method for improvement of the quality of geophysical data preparation on the example of geoacoustic observations to train neural networks when solving the problem of identification of pre- and post-seismic anomalies. The method is based on the transformation of geoacoustic emission signal associated with deformation processes in near-surface rocks into three-dimensional images. A series of such images contains the information on signal characteristics dynamics. Three-dimensional images are the matrices consisting of the the distribution vectors of selected characteristics (spectral, structural, statistical and so on). The structure, data tensor, is formed from a series of such images. It is supplied to the neural network input. Due to external factors impact (weather, industrial), a recorded geoacoustic signal is distorted. Thus, it is necessary to clean the initial data. In order to do this, we suggest using a neural network which clusters the prepared images and removes outliers in the obtained clusters. A new tensor is formed from the remaining images. It undergoes the cleaning procedure again. This process continues until no outliers are observed in the output data as the result of clustering. When the cleaning is over, the second neural network will be trained to identify common features and differences, as well as hidden patterns in the geoacoustic pulse flux. Application of the developed method for tensor cleaning, based on artificial intelligence technologies, allows us to improve significantly the quality of data preparation. The obtained results will be useful for the investigations in the fields of identification and classification of pre- and post-seismic anomalies in geoacoustic emission signals associated with deformation processes in near-surface rocks in a seismically active region.

*Key words:* geoacoustic emission, near-surface rocks, signal characteristics dynamics, clustering, neural networks, pre-seismic anomalies, postseismic anomalies.


Received: 07.11.2024; Revised: 19.11.2024; Accepted: 22.11.2024; First online: 28.11.2024

**For citation.** Senkevich Y. I., Mishchenko M. A. Question on the preparation of geoacoustic observation data for identification of pre- and post-seismic anomalies. *Vestnik KRAUNC. Fiz.-mat. nauki.* 2024, 49: 4, 125-134. EDN: PHFGUU. <https://doi.org/10.26117/2079-6641-2024-49-4-125-134>.

**Funding.** The work was supported by IKIR FEB RAS State Task (subject registration No. 124012300245-2)

**Competing interests.** The authors declare that there are no conflicts of interest regarding authorship and publication.

**Contribution and Responsibility.** All authors contributed to this article. Authors are solely responsible for providing the final version of the article in print. The final version of the manuscript was approved by all authors.

\*Correspondence:  E-mail: [senkevich@ikir.ru](mailto:senkevich@ikir.ru)

The content is published under the terms of the Creative Commons Attribution 4.0 International License

© Senkevich Y. I., Mishchenko M. A., 2024

© Institute of Cosmophysical Research and Radio Wave Propagation, 2024 (original layout, design, compilation)



## Введение

Процессы, происходящие в очаге готовящегося землетрясения, вызывают изменение напряженно-деформированного состояния земной коры на значительном удалении от самого очага. Под действием деформационных процессов в приповерхностных породах происходит генерация импульсных акустических сигналов — сигналов геоакустической эмиссии (ГАЭ) [1–3]. Результаты исследований [4–9] показывают, что динамика характеристик сигналов ГАЭ может быть связана с изменениями напряженно-деформированного состояния приповерхностных пород. Таким образом, через обнаружение аномального поведения динамики характеристик сигналов ГАЭ можно опосредованно фиксировать изменения свойств среды при подготовке землетрясений и последующей релаксации остаточных напряжений [10].

Аномалии поведения динамики характеристик геоакустических сигналов можно классифицировать, представляя их в виде изображений и применяя нейронные сети и технологии глубокого обучения для их распознавания. Использование нейронных сетей в обработке геофизических сигналов осложняется их высокой нелинейностью и нестационарностью [11]. Это приводит к появлению большого числа ошибок в ходе обработки и возникновению явления переобучения уже на малом числе эпох обучения сети.

Настоящее исследование посвящено методу очистки геоакустических данных для более качественной классификации аномалий ГАЭ и оценки напряженно-деформированного состояния приповерхностных пород в условиях постоянно протекающего сейсмо-тектонического процесса в Камчатском регионе.

## Средства наблюдения

Регистрация, обработка и анализ сигналов геоакустической эмиссии производится при помощи аппаратно-программного комплекса, состоящего из двух пространственно разнесенных частей: стационарной части и автономной части, расположенной в отдаленном пункте наблюдений. Пространственно-разнесенные части комплекса объединены в единую сеть на основе радиомодемов с антеннами. Структурная схема комплекса представлена на рис. 1.

Автономная часть комплекса осуществляет измерение геоакустических сигналов приповерхностных осадочных пород, их оцифровку, запись на жесткий диск, подключенный к компьютеру, и дальнейшую передачу данных на стационарную часть. Стационарная часть выполняет прием получаемых данных, их сохранение на дисковом RAID-массиве сервера.

На сервере также происходит подготовка данных (выделение потока импульсов в сигнале, вычисление их характеристик и формирование трехмерных изображений) и их последующий анализ с применением нейронных сетей.

Система регистрации построена на основе пьезокерамического гидрофона, который обеспечивает приём акустического сигнала в диапазоне частот от 0.1 Гц

до 10 кГц. Оцифровка регистрируемого сигнала производится с частотой дискретизации 48 кГц при помощи профессиональной звуковой карты M-Audio. Это позволяет регистрировать и записывать акустический сигнал в широком диапазоне частот в стандартном звуковом формате.



Рис. 1. Структурная схема аппаратно-программного комплекса.  
[Figure 1. Structural scheme of the hardware-software complex.]

## Методика подготовки данных

Фрагменты геоакустического сигнала преобразуются в 3D-отображения авторским методом [11]. Каждое отображение несет информацию о динамике выбранных (структурных, статистических, спектральных) характеристик сигнала за определенный период наблюдения. Будем рассматривать полученную серию отображений как множество, которое далее подвергается кластерному анализу. Это позволяет выделить подмножества близких по образу отображений динамики характеристик сигнала на различных фрагментах наблюдения — кластеры. Идентифицированные отображения собираются в тензоры данных для дальнейшей работы в сетях глубокого обучения для оценки напряжённо-деформированного состояния пород и идентификации пред- и постсейсмических аномалий. Для оценки качества обучения нейронной сети строились графики показателей точности классификации и ошибок классификации для обучающей и валидационной выборок.

Для подготовки обучающих тензоров использовался архив данных, полученных в ходе непрерывного мониторинга геоакустической эмиссии с сентября 2016 по декабрь 2019 года в пункте наблюдений «Карымшина». Строились отображения динамики распределения амплитуд геоакустических импульсов за период, равный 3 суткам. Отображения представлялись в формате RGB, размерностью  $256 \times 256$ .

Для обучения нейросети подготовлен набор отображений в сейсмически спокойные периоды и в окрестности сильных землетрясений. Рассматривались

землетрясения, произошедшие в период с сентября 2016 по декабрь 2019 года с энергетическим классом  $K_s$  не менее 10,0. В региональном сейсмическом каталоге [11, 12] зарегистрировано 981 такое событие. Из них были отобраны землетрясения, для которых выполнялось условие

$$D/R_D \leq 1, \quad R_D = 10^{0,43 \times (K_s - 4,6) / 1,5},$$

где  $R_D$  — радиус зоны Добровольского [13],  $D$  — расстояние от пункта наблюдений до гипоцентра землетрясения. Таким образом, было отобрано 31 землетрясение.

Было подготовлено три класса отображений, полученных накануне землетрясений («pred») — 31 отображение, непосредственно после землетрясений («post») — 31 отображение, и в сейсмически спокойный период («fon») — 325 отображений.

Количество данных в классах отличалось на порядок. Поэтому в ходе всех экспериментов выполнялось выравнивание данных с использованием синтетической генерации дополнительных копий. С этой целью применялся метод синтетической неполной избыточной выборки (SMOTE), решающий проблему дисбаланса классов. В результате исходный набор отображений увеличился практически в три раза (963 отображения). Кроме того, отмечая значимость классов «pred» и «post» в целевом обучении, был использован метод весового взвешивания. Для очистки кластеров отображений использовались методы из специализированной библиотеки для машинного обучения scikit-learn [14], реализующие обнаружение выбросов и дубликатов изображений на основе данных кластерного анализа. Значение порога выбросов для всех этапов экспериментов было постоянным и равным 0,90. Примеры получаемых отображений классов «pred», «post», «fon» представлены на рис. 2.

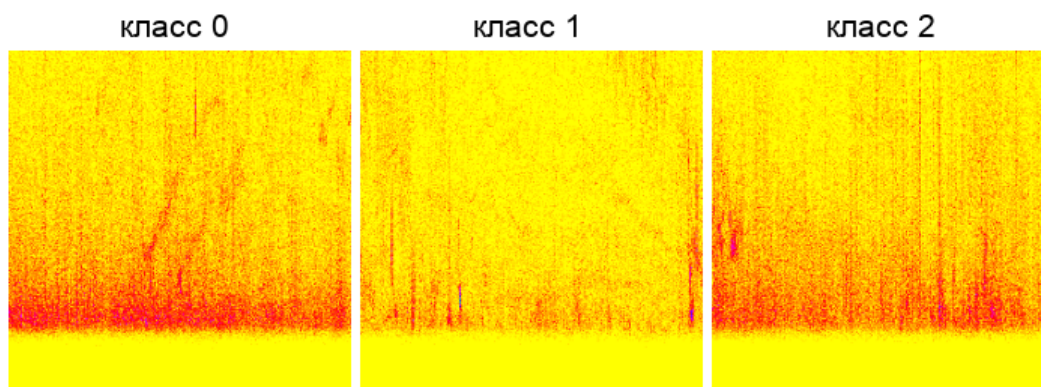


Рис. 2. Пример отображений классов: 0 — «pred», 1 — «fon», 2 — «post»  
[Figure 2. Example of class presentation: 0 — «pred», 1 — «fon», 2 — «post».]

Ниже представлены результаты серии экспериментов по обучению нейронной сети типа ResNet с использованием подготовленных тензоров данных с различным уровнем очистки. Структура разработанной сверточной нейронной сети на базе архитектуры ResNet представлена в табл. 1.

Таблица 1

**Структура сверточной нейронной сети на базе архитектуры ResNet**  
**[Structure of a convolution neural network based on ResNet architecture]**

Layer (type)	Output Shape	Param #	Connected to
img (InputLayer)	(None, 64, 64, 3)	0	–
layer1 (Conv2D)	(None, 62, 62, 64)	1,792	img[0][0]
layer2 (Conv2D)	(None, 60, 60, 64)	36,928	layer1[0][0]
max_pooling2d_1 (MaxPooling2D)	(None, 20, 20, 64)	0	layer2[0][0]
layer3 (Conv2D)	(None, 20, 20, 64)	36,928	max_pooling2d_1[0][0]
layer4 (Conv2D)	(None, 20, 20, 64)	36,928	layer3[0][0]
add_2 (Add)	(None, 20, 20, 64)	0	layer4[0][0], max_pooling2d_1[0][0]
layer5 (Conv2D)	(None, 20, 20, 64)	36,928	add_2[0][0]
layer6 (Conv2D)	(None, 20, 20, 64)	0	layer5[0][0]
add_3 (Add)	(None, 20, 20, 64)	0	layer6[0][0],add_2[0][0]
layer7 (Conv2D)	(None, 18, 18, 64)	36,928	add_3[0][0]
layer8 (Conv2D) (GlobalAveragePooling2D)	(None, 64)	0	layer7[0][0]
layer9 (Dense)	(None, 256)	16,640	layer8[0][0]
layer10 (Dropout)	(None, 256)	0	layer9[0][0]
layer11 (Dense)	(None, 3)	771	layer10[0][0]

Глобальные параметры нейросети при обучении составили: шаг движения по выборке — 32, количество итераций обучения — 64; объем валидационной выборки — 30%.

Таблица 2

**Описание параметров тензора данных в экспериментах**  
**[Description of data tensor parameters in the experiments]**

Класс	Число файлов до очистки	Число файлов после очистки	Размер обучающей выборки	Размер тестовой выборки
Эксперимент № 1				
fon	325	325	305	101
post	31	31	303	98
pred	31	31	298	96
Эксперимент № 2				
fon	325	321	235	86
post	31	28	223	98
pred	31	28	216	105
Эксперимент № 3				
fon	321	321	233	88
post	27	27	214	107
pred	27	26	227	94
Эксперимент № 4				
fon	321	321	212	89
post	27	26	216	98
pred	27	27	201	95

В эксперименте № 1 для подготовки тензора использовались данные без очистки. Так наглядно можно увидеть влияние выбросов на обучение подготовленной свёрточной нейросети. В экспериментах № 2, № 3 и № 4 для подготовки тензора использовались данные, полученные после одного, двух и трех этапов очистки соответственно. Параметры тензоров приведены в табл. 2.

## Обсуждение результатов

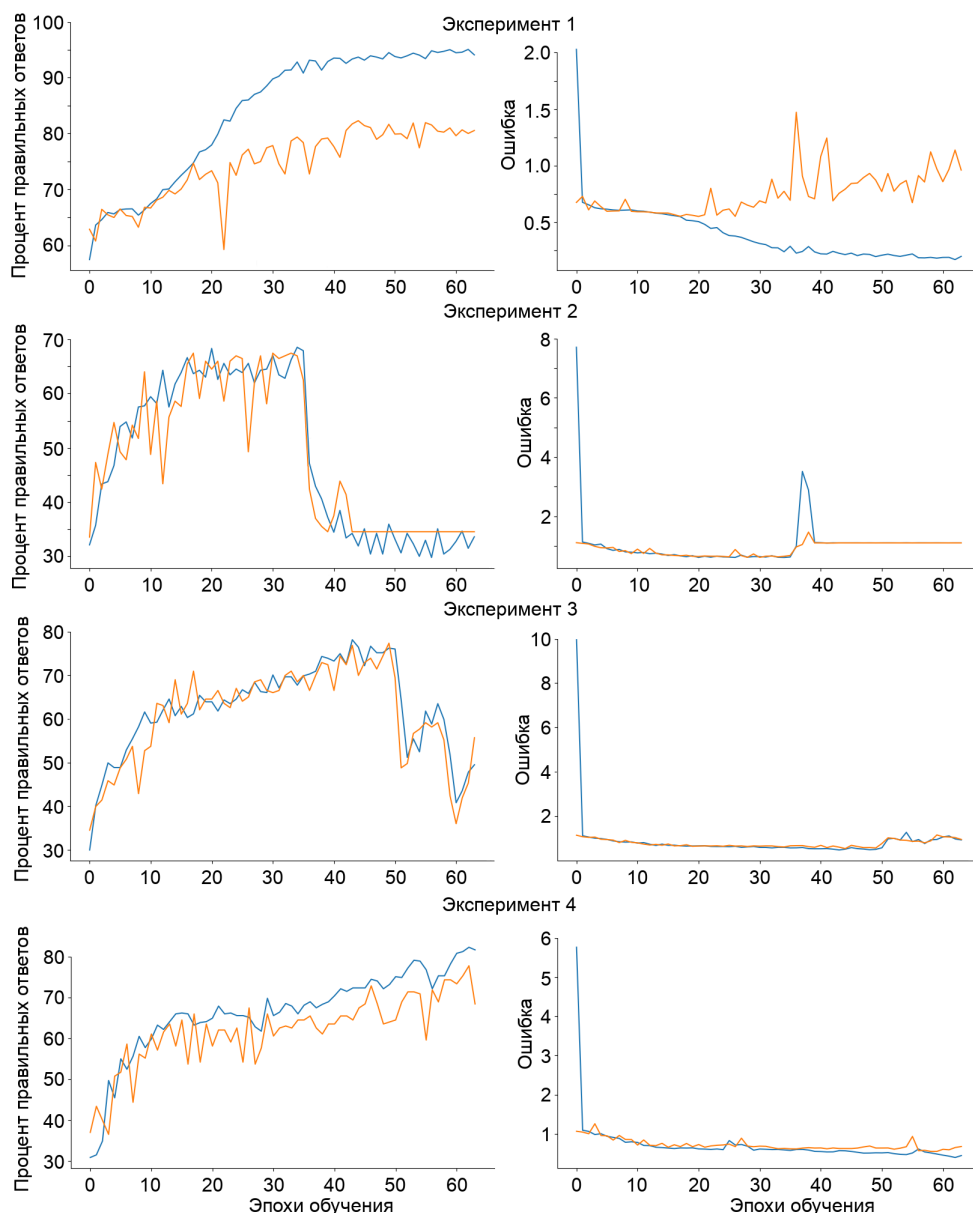


Рис. 3. Графики обучения сети для четырёх экспериментов. Графики для обучающей выборки — синяя линия, для тестовой выборки — оранжевая.  
 [Figure 3. Graphs of network training for four experiments. Graphs for the training sampling — blue line, for the test sampling — orange line.]

При обучении нейросети без очистки данных (рис. 3, эксперимент № 1) уже на 18 эпохе обучения наступает момент переобучения, что приводит к срыву данного процесса с быстро нарастающей ошибкой на валидационной выборке отображений. При первой же очистке данных (рис. 3, эксперимент № 2) результат обучения заметно улучшается, хотя и наблюдаются остаточные выбросы, порождаемые зашумленными данными.

На 36 эпохе наблюдается срыв процесса обучения нейросети с последующим отказом от обучения. Картина обучения на следующем этапе (рис. 3, эксперимент № 3) становится еще лучше. Срыв обучения наступает только на 46 эпохе, ошибка обучения становится меньше, чем на предыдущем этапе, а дисперсия выбросов заметно уменьшается. Завершение очистки кластеров отображений заканчивается на эксперименте № 4 (рис. 3, эксперимент № 4). Здесь картина обучения становится плавной, а показатели точности распознавания и минимума ошибки достигают наилучших значений. Отказ от обучения не присутствует. На завершение процесса очистки указывает следующий факт. Число отображений в кластерах на очередной итерации не изменяется, что можно принять как простое правило для определения этапа очистки данных.

## Заключение

Разработан метод подготовки геоакустических данных для обучения нейронных сетей в рамках решения задачи идентификации пред- и постсейсмических аномалий. В основе метода лежит преобразование геоакустического сигнала в серию трёхмерных изображений, несущую информацию о динамике распределения некоторых характеристик сигнала. Предлагается проводить очистку подготовленных серий изображений путем удаления выбросов, полученных по результатам кластеризации нейронной сетью. Установлено, что для качественной подготовки данных достаточно провести три цикла очистки.

Таким образом, применение технологий искусственного интеллекта для обработки геофизических данных позволяет поднять на новый уровень методы идентификации и классификации обнаруживаемых аномалий характеристик геоакустических сигналов, которые можно связать с влиянием деформационных процессов на приповерхностные осадочные породы.

## Список литературы


1. Марапулец Ю.В., Шевцов Б.М. *Мезомасштабная акустическая эмиссия*. Владивосток: Дальнаука, 2012. 126 с.
2. Пережогин А.С., Шевцов Б.М. Модели напряженно-деформированного состояния горных пород при подготовке землетрясений и их связь с геоакустическими наблюдениями // *Вычислительные технологии*, 2009. Т. 14, № 3, С. 48–57.
3. Марапулец Ю.В. и др. Отклик геоакустической эмиссии на активизацию деформационных процессов при подготовке землетрясений // *Тихоокеанская геология*, 2012. Т. 31, № 6, С. 59–67.
4. Моргунов В. А. и др. Геоакустический предвестник Спитакского землетрясения // *Вулканология и сейсмология*, 1991. № 4, С. 104–106.
5. Долгих Г.И. и др. Деформационные и акустические предвестники землетрясений // *Доклады академии наук*, 2007. Т. 413, № 1, С. 96–100.




6. Салтыков В. А., Кугаенко Ю. А. Развитие приповерхностных зон дилатансии как возможная причина аномалий в параметрах сейсмической эмиссии перед сильными землетрясениями // *Тихоокеанская геология*, 2012. Т. 31, № 1, С. 96–106.
7. Gregori G. P., et. al. “Storms of crustal stress” and AE earthquake precursors // *Natural Hazards and Earth System Sciences*, 2010. vol. 10, no. 2, pp. 319–337.
8. Lukovenkova O., Marapulets Yu., Solodchuk A. Adaptive approach to time-frequency analysis of AE signals of rocks // *Sensors*, 2022. vol. 22, no. 24, pp. 1–13, 9798.
9. Gapeev M., Marapulets Y. Modeling Locations with Enhanced Earth’s Crust Deformation during Earthquake Preparation near the Kamchatka Peninsula // *Appl. Sci.*, 2022. vol. 13, no. 1, pp. 1–14, 290.
10. Marapulets Y., et al. Sound Range AE as a Tool for Diagnostics of Large Technical and Natural Objects // *Sensors*, 2023. vol. 23, no. 3, pp. 1–14, 1269.
11. Сенкевич Ю. И. и др. Методика выделения информативных признаков в сигналах геоакустической эмиссии // *Труды СПИИРАН*, 2019. Т. 18, № 5, С. 1066–1092 DOI: 10.15622/sp.2019.18.5.1066-1092.
12. *Каталог землетрясений Камчатки и Командорских островов*, Камчатский филиал ФИЦ ЕГС РАН, [Электронный ресурс]. URL: <http://sdis.emsd.ru/info/earthquakes/catalogue.php> (дата обращения: 20.11.24).
13. Чеброва А. Ю. и др. Единая информационная система сейсмологических данных в Камчатском филиале ФИЦ ЕГС РАН: принципы организации, основные элементы, ключевые функции // *Геофизические исследования*, 2020. Т. 21, № 3, С. 66–91.
14. Добровольский И. П. *Математическая теория прогноза и подготовки тектонического землетрясения*. М.: ФИЗМАТЛИТ, 2009. 240 с.
15. Pedregosa F., et al. Scikit-learn: Machine Learning in Python // *Journal of Machine Learning Research*, 2011. vol. 12, no. 85, pp. 2825–2830.

### Информация об авторах



*Сенкевич Юрий Игоревич* ✉ – доктор технических наук, доцент, ведущий научный сотрудник лаборатории акустических исследований, Институт космофизических исследований и распространения радиоволн ДВО РАН, Паратунка, Россия,  ORCID 0000-0003-0875-6112.




*Мищенко Михаил Александрович* ✉ – кандидат физико-математических наук, ведущий научный сотрудник лаборатории акустических исследований, Институт космофизических исследований и распространения радиоволн ДВО РАН, Паратунка, Россия,  ORCID 0000-0003-1958-5830.

## References


- [1] Marapulets Yu. V., Shevtsov B. M. Mesoscale acoustic emission [Mezomasshtabnaya akusticheskaya emissiya], Vladivostok, Dalnauka, 2012, 126 p. (In Russian).
- [2] Perezhogin A. S., Shevtsov B. M. Models of an intense-deformed condition of rocks before earthquakes and their correlation with geo-acoustic emission, Computational Technologies, 2009, vol. 14, no. 3, pp. 48–57, (In Russian).
- [3] Marapulets Y. V., et. al. Geoacoustic emission response to deformation processes activation during earthquake preparation, Rus. J. of Pac. Geol, 2012, no. 6, 457–464. DOI: 10.1134/S1819714012060048.
- [4] Morgunov V. A., et. al. Geoacoustic harbinger of the Spitak earthquake, Journal of Volcanology and Seismology, 1991, no. 4, pp. 104–106 (In Russian).
- [5] Dolgikh G. I., et al. Deformation and acoustic precursors of earthquakes, Doklady Earth Sciences, 2007, vol. 413, no. 1, pp. 281–285. DOI: 10.1134/S1028334X07020341.
- [6] Saltykov V. A., Kugaenko Y. A. Development of near-surface dilatancy zones as a possible cause for seismic emission anomalies before strong earthquakes [Razvitie pripoverhnostnyh zon dilatatsii kak vozmozhnaja prichina anomalij v parametrah sejsmicheskoy jemissii pered sil'nymi zemletrjasenijami], Rus. J. of Pac. Geol., 2012, vol. 6, no. 1 pp. 86–95, (In Russian).
- [7] Gregori G. P., et. al. “Storms of crustal stress” and AE earthquake precursors, Natural Haz. and Earth Sys. Sci., 2010. vol. 10, no. 2, pp. 319–337. DOI: 10.5194/nhess-10-319-2010.
- [8] Lukovenkova O., Marapulets Yu., Solodchuk A. Adaptive approach to time-frequency analysis of AE signals of rocks, Sens., 2022, vol. 22, no. 24:9798, DOI: 10.3390/s22249798.
- [9] Gapeev M., Marapulets Y. Modeling Locations with Enhanced Earth’s Crust Deformation during Earthquake Preparation near the Kamchatka Peninsula, Applied Sciences, 2022, vol. 13, no. 1:290, pp. 1–14. DOI: 10.3390/app13010290.
- [10] Marapulets Y., et. al. Sound Range AE as a Tool for Diagnostics of Large Technical and Natural Objects, Sensors, 2023, vol. 23, no. 3:1269, pp. 1–14. DOI: 10.3390/s23031269.
- [11] Senkevich Yu., et. al. Technique of informative features selection in geoacoustic emission signals [Metodika vydelenija informativnyh priznakov v signalah geoakusticheskoy jemissii], SPIIRAS, 2019, vol. 18, no. 5, pp. 1066–1092. DOI: 10.15622/sp.2019.18.5.1066-1092.
- [12] Kamchatka Branch of the Geophysical Survey of the Russian Academy of Sciences, Earthquakes Catalogue for Kamchatka and the Commander Islands. URL: <http://sdis.emsd.ru/info/earthquakes/catalogue.php> (access: 20.11.24).
- [13] Chebrova A. Yu., et. al. Seismological data information system in Kamchatka branch of GS RAS: organization principles, main elements and key functions, Geophysical Research, 2020, vol. 21, no. 3, pp. 66–91.
- [14] Dobrovolskiy I. P. Mathematical theory of prediction and preparation of a tectonic earthquake [Matematicheskaya teoriya podgotovki i prognoza tektonicheskogo zemletrjaseniya], Moscow, FIZMATLIT, 2009, 240 p. (In Russian).
- [15] Pedregosa F., et al. Scikit-learn: Machine Learning in Python, Journal of Machine Learning Research, 2011, vol. 12, no. 85, pp. 2825–2830.

### Information about the authors



*Senkevich Yury Igorevich* ✉ – D. Sci. (Tech.), Docent, Leading Researcher, Lab. of Acoustic Research, IKIR FEB RAS, Paratunka, Russia,  ORCID 0000-0003-0875-6112.



*Mishchenko Mikhail Aleksandrovich* ✉ – Ph. D. (Phys. & Math.), Leading Researcher, Lab. of Acoustic Research, IKIR FEB RAS, Paratunka, Russia,  ORCID 0000-0003-1958-5830.