

Анализ скорости счёта гамма-квантов, регистрируемых в подземном детекторе LVD, с целью предсказания сильных сейсмических событий

Студент:
Комлык Егор Романович

Научный руководитель:
Агафонова Наталья Юрьевна


Цели

Целью работы является на основе экспериментальных данных по скорости счета гамма-квантов, регистрируемых детектором LVD, построить с применением машинного обучения модель для обнаружения предвестниковой фазы землетрясений.

Задачи


- Изучить работы, посвящённые исследованию отклика детектора LVD на сейсмические события.
- Проанализировать экспериментальные данные с целью выделения характерных для предвестников землетрясений форм сигнала.
- Найти подход к решению задачи по поиску предвестников землетрясений с точки зрения машинного обучения.

Описание LVD




Глубина залегания – 3650 м в.э.


Назначение: поиск разных типов нейтрино от гравитационных коллапсов звездных ядер в нашей Галактике.




Длина	22.7 м
Ширина	13.2 м
Высота	10.0 м
Масса сцинтиллятора	1008 т
Число счётчиков	840
Число ФЭУ	2520



Основная реакция – обратный бета-распад (IBD):




Два порога регистрации:



Триггерный $E_{HET} = 4 \text{ МэВ}$,
низкоэнергетичный $E_{LET} = 0.5 \text{ МэВ}$

Фон: атмосферные мюоны (средняя энергия которых около 280 ГэВ, скорость счёта мюонов на счетчик $\sim 10^{-4} \text{ сек}^{-1} \text{ счётчик}^{-1}$), и естественная радиоактивность скального грунта и материалов установки (для внутренних счетчиков первой башни $\sim 45 \text{ сек}^{-1} \text{ счётчик}^{-1}$).

Радоновый фон и предвестники землетрясений





Гамма-излучение создаётся в основном ядрами $^{214}_{83}Bi$, $E_\gamma = 0.6 - 2.5$ МэВ

Сейсмические события 2019 г. с
магнитудой больше 3.5 и отклик
установки LVD:

слева (а) – показаны эпицентры сильных толчков и их расположение относительно установки LVD;

справа (*б*, *в*, *г*) – данные установки по нижнему порогу (по оси абсцисс – дата, по оси ординат – темп счета в секунду на счетчик).


Линиями обозначены моменты сильных толчков.



Описание данных

Лабораторные данные – временные ряды:

- Скорость счёта гамма-квантов
- Радон



	Date	Count_rate_1	Count_rate_2	Count_rate_3	Pressure_1	Pressure_2	Pressure_3	Pressure_4
0	2004-01-10 19:00:00+00:00	54.193	54.480	82.111	760.69	760.44	760.83	760.92
1	2004-01-10 20:00:00+00:00	54.726	54.055	82.918	761.40	761.18	761.45	761.60
...
168961	2023-04-20 20:00:00+00:00	37.814	40.825	61.653	760.17	759.91	760.14	760.18
168962	2023-04-20 21:00:00+00:00	38.103	41.439	60.807	760.35	760.17	760.17	760.23

168963 rows × 8 columns

Источники данных землетрясений:


- Камчатский филиал ФИЦ ЕГС РАН (EMSD)
- Глобальная база данных значительных землетрясений NCEI/WDS (NOAA)
- Департамент землетрясений национального института геофизики и вулканологии Италии (INGV)
- Геофизическая служба РАН (GSRAS)

	Date	Latitude	Longitude	Depth	Magnitude	Distance_from_LVD	Intensity
0	2004-01-01 00:08:09+00:00	49.65	156.440	17.0	4.0	9184.202815	-4.870648
1	2004-01-01 20:59:31.900000+00:00	-8.31	115.788	45.0	5.8	11637.177401	-2.530478
...
34897	2025-03-05 05:21:51.300000+00:00	52.24	159.940	27.0	3.9	9030.266499	-4.994959
34898	2025-03-14 19:37:15+00:00	41.98	15.350	10.0	5.0	159.163411	2.790554


34899 rows × 7 columns

Фильтрация данных


All Earthquake Data



Filtered Earthquake Data



Определение интервала прогнозирования




Параметры обнаружения пиков:

- Минимальное расстояние – 12
- Минимальная амплитуда – $\sigma/2$

аномальное поведение радона перед землетрясением →
→ определение величины интервала между пиком и землетрясением →
→ ориентировочные значения для дальнейшего анализа

Среднее количество дней в лаге: 5.68

- σ – 7 дней – 73.9% лагов
- 2σ – 14 дней – 89.3% лагов
- 3σ – 21 день – 95.1% лагов



Поиск корреляций


Для каждой даты проверялось наличие в ближайшие 24-144 часа после неё землетрясения, результат проверки принимал значение 0 или 1. Далее рассчитывалась корреляция при разных сдвигах (± 14 дней) между датами двух векторов значений.



Поиск паттернов радона


Для каждого землетрясения берётся окно ± 14 дней вокруг даты события, из радонового ряда вырезается соответствующий фрагмент и нормируется относительно среднего в окне уровня радона. Далее все эти фрагменты усредняются между собой, получается «средняя форма сигнала» до и после землетрясения.

Характерные пики за 5.6, 4.8, 3.5 дня до события.







Проверка паттерна радона на устойчивость

Среднее поведение радона ± 14 дней вокруг землетрясений



Выборки – случайные подмножества землетрясений в размере 10% от всего массива данных каждое.


- Паттерн наблюдается на выборках в 10%, но не всегда и не полностью
- Основной и самый стабильный пик – за 3.5 дня до события
- В ожидаемом диапазоне пиков среднее значение радона зачастую выше, чем в предыдущие дни



Проверка паттерна радона на значимость


Выборка – случайное подмножество дат без землетрясений, размер равен всей выборки дат с землетрясениями.

Выделенный паттерн, как и какое-либо аномальное поведение, не наблюдается.




Поиск паттернов давления





Гладкий пик за 1-2 дня до землетрясения в конце тренда на рост длительностью приблизительно 6 дней.



Проверка паттерна давления на устойчивость




За 1-3 дня до события наблюдается небольшой пик.



Проверка паттерна давления на значимость

Выделенный паттерн, как и какое-либо аномальное поведение, не наблюдается.



Формирование целевой переменной

Исходная постановка: «оценка вероятности возникновения землетрясения с $M \geq n$ в радиусе $R \leq m$ км в течение следующих k суток», где $n = M_{min}$ – минимальная магнитуда, $m = R_{max}$ – максимальное расстояние от LVD.

Фактически не прогнозируется вероятность землетрясения, а даётся оценка (score) состояния, в котором на данный момент находится система.

Задача бинарной классификации: грубо говоря, модель должна ответить на вопрос, будет в ближайшие k суток землетрясение или нет. Таким образом, формирование целевых меток происходит по следующему принципу:

$$y_t = 1, \text{ если } \exists \text{ дата землетрясения } \in [t + 1, t + k]$$

- $k > 2$ – дисбаланс в сторону целевого класса
- $k = 2$ – баланс классов
- $k = 1$ – дисбаланс в сторону нулевого класса, число меток равно числу землетрясений

Преобразование данных

	Count_rate_1	Count_rate_2	Count_rate_3	Pressure_1	Pressure_2	Pressure_3	Pressure_4
0	54.193	54.480	82.111	760.69	760.44	760.83	760.92
1	54.726	54.055	82.918	761.40	761.18	761.45	761.60
...
168961	37.814	40.825	61.653	760.17	759.91	760.14	760.18
168962	38.103	41.439	60.807	760.35	760.17	760.17	760.23

168963 rows × 7 columns





усреднение по башням

	Count_rate_avg	Pressure_avg
0	63.594667	760.653333
1	63.899667	761.343333
...
168961	46.764000	760.073333
168962	46.783000	760.230000

группировка и агрегация по суткам

Date	Count_rate_avg_min	Count_rate_avg_max	Count_rate_avg_mean	Count_rate_avg_std	Count_rate_avg_var	Count_rate_avg_median
2004-01-10	62.094667	63.899667	63.042067	0.719298	0.517389	62.920333
2004-01-11	59.993667	61.943333	60.673222	0.533638	0.284769	60.558667
...
2023-04-19	46.742000	49.203000	47.628986	0.739322	0.546597	47.420333
2023-04-20	46.764000	50.035000	47.843182	0.931478	0.867651	47.775000

7041 rows × 12 columns



- Ранее выявленные явные пики радона стали выглядеть как заметный тренд на рост
- Картина для давления практически не изменилась

Формирование признаков на основе паттернов

k = 2 (baseline)

- Максимум радона
- Число шагов до максимума радона
- Максимум давления
- Число шагов до максимума давления
- Возрастающий тренд (линейная интерполяция) радона
- Убывающий тренд радона
- Тренд давления
- Отношение возрастающего тренда радона к тренду давления

k = 1

- Тренд радона
- Монотонность тренда радона
- Изменение тренда радона
- Находится ли максимум в окне 2-4 до текущей даты
- Выступ пика
- Спад после пика
- Скорость спада
- Интегральное превышение радона
- Волатильность радона

Аналогичные признаки для давления

Совместные:

- Совпадение трендов
- Пик радона раньше пика давления
- Отношение интегральных превышений радона и давления

8 признаков

11 + 8 + 3 = 22 признака



Результаты обучения

	Логистическая регрессия	Метод опорных векторов	Градиентный бустинг	
1	0.481	0.882	0.493	1.000
2	0.364	0.536	0.373	0.000

Precision | Recall

$$Precision = \frac{TP}{TP + FP}$$

$$Recall = \frac{TP}{TP + FN}$$



Возможные проблемы и альтернативы

Возможные проблемы:

- Фундамент решения – агрегация исходных данных по суткам – сглаживание фона, но потеря информации
- Акцент на исходные данные в процессе анализа, но почти отсутствие анализа извлечённых признаков
- Расчёт практически всех признаков на основе только суточного среднего, игнорирование других результатов агрегации

Альтернативы:

- Агрегация по меньшим окнам: не 24, а 12 или 6 – это может поспособствовать сохранению ключевых значений временного ряда и при этом сократить шум
- Анализ извлечённых признаков: группировка и расчёт статистик, попарная визуализация признаков, метод главных компонент и др.
- Использовать разные исходные данные для разных признаков / обучать модель и с использованием результатов агрегации

В данной работе была попытка контекст учесть через формирование признаков на основе предыдущих значений. Можно также попробовать построить небольшую нейронную сеть с использованием рекуррентных блоков.

Заключение

- В ходе анализа были выявлены и подтверждены ключевые идеи, лежащие в основе исследования
- Были протестированы несколько из множества возможных подходов к решению задачи при помощи машинного обучения
- Несмотря на неудовлетворительный итоговый результат, остаётся большой простор для дальнейших экспериментов и работы с данными