

МАТЕМАТИЧЕСКОЕ МОДЕЛИРОВАНИЕ В ЯДЕРНЫХ ТЕХНОЛОГИЯХ

УДК 539.1.08

ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ В ЭКСПЕРИМЕНТЕ БАЙКАЛ-GVD

© 2024 г. И. В. Харук^{a, b, *}, А. В. Мацейко^{a, b}, А. Ю. Леонов^{a, b}

^aИнститут ядерных исследований Российской академии наук, Москва, 117312 Россия

^bМосковский физико-технический институт, Долгопрудный, 141700 Россия

*E-mail: ivan.kharuk@phystech.edu

Поступила в редакцию 13.06.2023 г.

После доработки 21.06.2023 г.

Принята к публикации 03.07.2023 г.

Эксперимент Байкал-GVD — это нейтринный телескоп, расположенный в озере Байкал, Россия. По состоянию на 2022 г., его эффективный объем составляет 0.5 км^3 , что делает его крупнейшим нейтринным телескопом в северном полушарии и вторым по величине в мире. В настоящей работе представлен обзор методов машинного обучения, разработанных для анализа данных эксперимента Байкал-GVD. А именно, обсуждаются нейронные сети, разработанные для: (1) подавления шумовых срабатываний оптических модулей, (2) выделения событий, индуцированных нейтрино, а также оценки их потока, и (3) восстановления угла прилета нейтрино. Показано, что нейронные сети сравнимы или превосходят по точности стандартные алгоритмические процедуры реконструкции событий для аналогичных задач.

Ключевые слова: нейтрино, Байкал-GVD, машинное обучение, нейронные сети, анализ данных

DOI: 10.56304/S2079562923010116

1. ВВЕДЕНИЕ

Экспериментальная нейтринная астрофизика является активно развивающейся областью физики. Это обусловлено рядом уникальных свойств нейтрино. Так, в отличие от адронов, нейтрино не подвержены влиянию космологических магнитных полей. По этой причине, реконструированное направление прилета нейтрино напрямую указывает на его источник. Также, в отличие от фотонов, вселенная практически прозрачна для нейтрино любых энергий. Наконец, нейтрино представляют интерес в контексте многоканальной астрономии. Вместе с электромагнитным излучением, гравитационными волнами, и космическими лучами, оно формирует четверку потенциальных наблюдаемых для различных космологических процессов. Регистрация или, наоборот, отсутствие сигнала по некоторым из перечисленных каналов позволяет уточнить физику соответствующих процессов.

Принцип работы нейтринных телескопов основан на том, что нейтрино при взаимодействии со средой может порождать адронные ливни и релятивистские частицы, излучающие черенковское излучение. Рождающиеся при этом фотоны регистрируются с помощью оптических модулей (ОМ), сигналы с которых используются для реконструкции энергии и угла прилета нейтрино. Для реги-

страции астрофизических нейтрино с энергией порядка $1 \text{ TeV} - 100 \text{ PeV}$ и восстановления их параметров требуются эффективные объемы установки порядка 1 км^3 . Подобных значений оказывается возможным достичь, используя натуральные резервуары, воду или лед, в качестве среды, в которой размещены детекторы.

В настоящее время готовы или находятся на стадии развертывания три нейтринных телескопа с эффективным рабочим объемом порядка 1 км^3 — это IceCube [1], Байкал-GVD [2, 3], и KM3NeT [4]. Эксперимент IceCube расположен в южном полушарии, в Антарктике, и имеет эффективный объем 1 км^3 . В настоящее время идет развертывание следующей стадии данного эксперимента, IceCube-Gen2 [5], что увеличит объем детектора в 10 раз. KM3NeT, расположенный в Средиземном море, находится на начальных этапах развертывания и состоит из двух частей — ORCA и ARCA. Эксперимент ORCA нацелен на изучение осциллирующих нейтрино при энергиях порядка нескольких GeV, в то время как ARCA нацелен на изучение астрофизических нейтрино с энергиями в диапазоне от нескольких TeV до десятков PeV.

Эксперимент Байкал-GVD расположен в озере Байкал, Россия, и является крупнейшим нейтринным телескопом в северном полушарии. По состоянию на 2022 год, его эффективный объем со-

ставляет 0.5 км^3 для каскадо-подобных событий, индуцированных нейтрино. Целевого эффективного объема детектора, 1 км^3 , планируется достичь к 2030 г. Целью эксперимента является изучение и идентификация астрофизических нейтрино в TeV-PeV диапазоне. В отличие от IceCube, Байкал-GVD является водным нейтринным телескопом, что уменьшает перерассеяние света в среде. Благодаря этому, Байкал-GVD имеет лучшее угловое разрешение для каскадо-подобных нейтринных событий. Стоит также отметить, что эксперименты Байкал-GVD и IceCube являются географически комплементарными — объединение накопленных ими данных позволяет делать астрофизические обзоры полного неба.

Экспериментальная установка Байкал-GVD устроена следующим образом [6]. Базовыми компонентами детектора являются оптические модули со встроенным в них 25-сантиметровыми фотоумножителями Hamamatsu R7081-100 с высокой квантовой эффективностью. Фотоумножители направлены вглубь озера. Это обусловлено тем, что из-под земли могут прилететь только нейтрино, в то время как сверху имеется большой фон от широких атмосферных ливней (ШАЛ). OM объединяются в вертикальные струны. На каждой струне находится 36 OM, расположенных на глубине от 750 до 1275 м с шагом в 15 м. В свою очередь, 8 струн объединяются в кластер. В горизонтальном разрезе кластеры представляют собой приблизительно правильный семиугольник, через вершины и центр которого проходят струны. По состоянию на 2022 год, всего развернуто 11 кластеров. Средний радиус кластера — 60 м, а среднее расстояние между кластерами составляет около 300 м.

Для измерения положений OM в режиме реального времени используется система акустического позиционирования детекторов. Временная калибровка OM осуществляется с помощью системы лазеров, позволяющей добиться точности идентификации времен срабатываний OM около 3 нс.

Запись данных детектора для дальнейшего анализа происходит при выполнении следующего условия: два соседних OM зарегистрировали импульсы с энерговыделением как минимум 4.5 и 1.5 фото-электрона (ф. э.) во временном интервале 100 нс. Если данное условие выполнено, записываются сигналы со всех OM, заряд на которых превысил порог в 0.3 ф. э.. В дальнейшем мы будем называть подобные записи событиями.

В настоящей работе мы остановимся на рассмотрении трех задач, для которых были разработаны методы машинного обучения. А именно, в параграфе 2 рассматривается задача подавления шумовых срабатываний OM, вызванных естественной люминесценцией воды. В параграфе 3 излагается метод разделения событий, индуцированных нейтрино и ШАЛ, а также метод для измерения по-

тока нейтрино. Результаты применения нейронных сетей для реконструкции угла прилета нейтрино изложены в параграфе 4. Примеры применения машинного обучения для анализа данных в других нейтринных телескопах можно найти в работах [7–11].

2. ПОДАВЛЕНИЕ ШУМОВЫХ СРАБАТЫВАНИЙ OM

В озере Байкал имеется натуральная люминесценция воды. Ее основным источником являются естественные химические и биологические процессы. OM детектора, в силу своей высокой чувствительности, регистрируют данное излучение. Соответствующие срабатывания OM, которые мы в дальнейшем будем называть шумовыми, нескоррелированы, и их спектр хорошо изучен. Шумовые срабатывания, в зависимости от глубины и времени года, имеют частоту в диапазоне 20–100 Гц, а выделяемый на OM заряд имеет порядок 1 ф. э. В среднем, шумовые срабатывания OM составляют около 90% от всех данных. Несумовые срабатывания OM, обусловленные распространением релятивистских частиц в рабочем объеме детектора, мы будем называть сигнальными.

Для подавления шумовых срабатываний OM можно было бы увеличить порог для записи с 0.3 ф. э. до нескольких ф. э.. Однако, это приведет к потере части сигнальных хитов. Это нежелательно, поскольку для точной реконструкции событий (восстановления угла прилета нейтрино и его энергии) необходимо сохранять максимально возможное количество сигнальных срабатываний OM. Это является мотивацией для разработки нейронной сети для данной цели.

Тренировка нейронных сетей проходит на обучающих данных. Реальные экспериментальные события для этого не подходят, поскольку для них неизвестно, какие срабатывания OM являются шумовыми, а какие сигнальными. Поэтому необходимо использовать Монте-Карло симуляцию данных, в которой можно отследить происхождение всех сигналов, зарегистрированных OM.

Для симуляции работы детектора рассматривались два типа событий. Первые — это события, индуцированные ШАЛ. Часть рождающихся в ШАЛ релятивистских мюонов долетают до уровня OM в воде, вызывая адронные каскады и испуская черенковское излучение. Свет от данных процессов регистрируется OM, что приводит к регистрации событий. Без последующей обработки данных невозможно отличить события, индуцированные ШАЛ, от событий, индуцированных нейтрино. По этой причине ШАЛ-индуцированные события невозможно отбросить, и они составляют большую часть регистрируемых детектором событий.

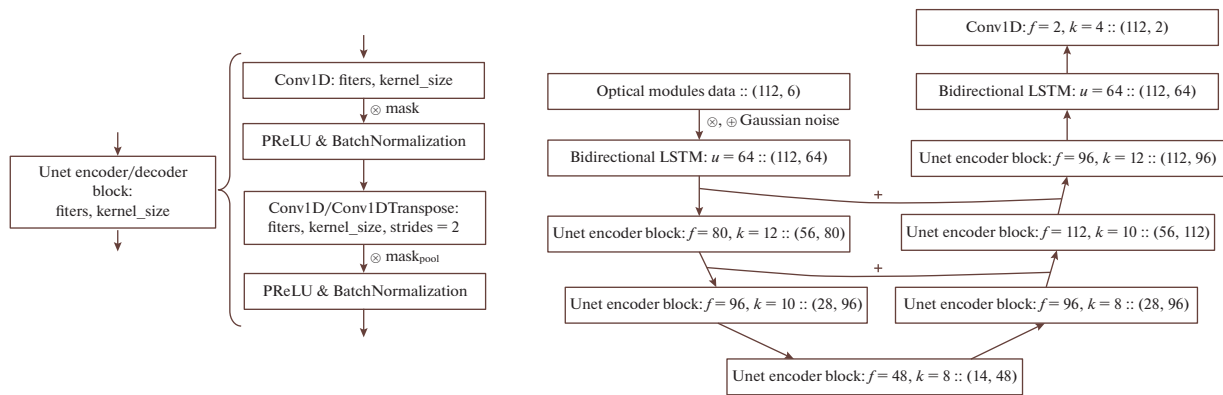


Рис. 1. Архитектура нейронной сети для подавления шумовых срабатываний ОМ.

Второй тип рассматриваемых событий — это события, индуцированные мюонным нейтрино. При распространении в воде они могут провзаимодействовать со средой через нейтральные или заряженные токи, порождая релятивистский мюон и адронные каскады. В силу схожести протекающих процессов, оказывается невозможным отличить одиночный мюон, прилетевший от ШАЛ, от мюона, порожденного нейтрино, прилетевшего также сверху (с неба). В силу этого симулируются только нейтрино, прилетающие из-под земли — их можно отличить по направлению распространения сигнала. Нейтрино других ароматов в данной работе рассматриваться не будут.

Процедура Монте-Карло симуляции ливней включает в себя полное моделирование ШАЛ и отклика установки. Также учитывается перерасcеяние света в воде. Шумовые срабатывания ОМ разыгрываются случайным образом, в соответствии со спектром и частотой, измеренными экспериментально.

Сигнал, регистрируемый ОМ, разбивается на набор дискретных импульсов, также называемых хитами. Каждый импульс соответствует некоторому пику на временной развертке сигнала и характеризуется следующими величинами: (1–3) координаты ОМ, зарегистрировавшего сигнал; (4) время регистрации сигнала; (5) интегральный заряд, выделенный за время импульса. Также каждый импульс сопровождается флагом, указывающим источник его происхождения. Данные флаги были нами упрощены до бинарной маски, отражающей, является ли хит сигнальным или шумовым. Подобный набор данных позволяет сформулировать задачу подавления шумовых срабатываний ОМ как задачу сегментации — для каждого хита необходимо предсказать, какому классу (шум или сигнал) он принадлежит.

Полный набор Монте-Карло симулированных событий, использованный нами, составляет примерно 10^7 событий каждого типа. Чтобы избежать

баеса, связанного с разной сигнатурой ШАЛ- и нейтрино-индуцированных событий, для тренировки нейронной сети было взято одинаковое количество событий обоих типов. Экспериментально было установлено, что метрики сети не сильно чувствительны к изменению выбранной нами пропорции. Монте-Карло набор данных был разбит на тренировочный, тестовый, и валидационный наборы в пропорции 8 : 1 : 1.

Мы использовали следующее представление данных — все ОМ, сработавшие в событии, упорядочивались в одномерный ряд в соответствии со временем их срабатывания. Физическая мотивация данного выбора заключается в том, что сигнальные хиты расположены близко по времени, то есть, кластеризуются. Это упрощает задачу поиска сигнальных хитов для нейронной сети, а также делает временную структуру события явной. Нами были также опробованы другие варианты представления данных, такие как использование трехмерного массива, симулирующего геометрическую структуру кластера. Однако, они оказались менее эффективными.

Используемая нами нейронная сеть имеет U-net подобную архитектуру [12]. Для предсказания класса отдельного хита, U-net использует как локальную информацию от соседних хитов, так и глобальную, характеризующую события в целом. Руководствуясь тем, что данные представляют времениупорядоченный ряд, мы также добавили по одному рекуррентному слою (а именно, LSTM) до и после U-net блока. Это позволило улучшить метрики сети. Схематическое изображение архитектуры разработанной нами нейронной сети приведено на рис. 1.

Для оценки эффективности работы нейронной сети мы использовали следующие метрики:

- чистота отбора — доля верно предсказанных сигнальных хитов по отношению ко всему, распознанному сетью как сигнальные хиты;

- полнота отбора — доля верно предсказанных сигнальных хитов по отношению ко всем сигнальным хитам;
- дисперсия времен запаздывания.

Время запаздывания — это разница во времени между ожидаемым моментом регистрации сигнала и фактическим, возникающая вследствие перерасеяния света в воде. Данная метрика важна, поскольку для точной реконструкции угла прилета нейтрино следует отбирать хиты только с небольшими временами запаздывания.

В целях уменьшения дисперсии времен запаздывания, мы использовали специальную функцию потерь. Помимо штрафа за предсказание неверного класса хита, она также дополнительно штрафует нейронную сеть за выбор хитов с большими временами запаздывания в качестве сигнальных. Данный прием позволил уменьшить соответствующую метрику на 10%.

Для сравнения разработанного метода со стандартными алгоритмами подавления шумов [2, 13], мы выбрали порог классификации, при котором дисперсии времен запаздывания в обоих подходах одинаковы и равны 5 нс. В данной точке значение чистоты и полноты отбора с помощью нейронной сети составляют 99.5 и 96%, соответственно. Это лучше аналогичных метрик для алгоритмического подхода на 4 и 1%, соответственно.

3. РАЗДЕЛЕНИЕ ШАЛ- И НЕЙТРИНО-ИНДУЦИРОВАННЫХ СОБЫТИЙ

После очистки данных от шумовых срабатываний ОМ, становится возможным решать следующую задачу — выделение нейтрино-индуцированных событий. Именно подобные события представляют главный интерес для дальнейшей реконструкции углов прилета и энергий частиц.

На одно нейтрино-индуцированное событие приходится около $10^6 - 10^7$ ШАЛ-индуцированных событий. Большую часть ШАЛ-индуцированных событий можно идентифицировать, определив направление распространения мюона в воде. Однако, данный подход имеет недостаточную дискриминационную силу для каскадо-подобных событий. Для достижения требуемой чистоты отбора приходится накладывать дополнительные фильтры, уменьшающие экспозицию нейтрино-индуцированных событий. Указанные факторы мотивируют создание нейронной сети для решения данной задачи.

В качестве обучающих данных для нейронной сети использовалась Монте-Карло симуляция работы детектора, описанная выше. Шумовые хиты были предварительно отфильтрованы нейронной сетью, описанной в предыдущем параграфе. Для каждого события известно, является оно нейтрино- или ШАЛ-индуцированным. Это позволяет

сформулировать рассматриваемую задачу как задачу бинарной классификации.

Мы опробовали различные форматы представления данных. Времени-упорядоченное представление оказалось наиболее эффективным также и для данной задачи.

В качестве базовой архитектуры нейронной сети была выбрана стандартная сверточная сеть с постепенным уменьшением размерности данных (“длины” событий) и сквозными соединениями слоев. Добавление рекуррентного LSTM блока до и после сверточной части сети позволило улучшить метрики сети, а также естественным образом исключить зависимость количества параметров нейронной сети от длины входных данных.

Для обучения сети мы использовали так называемую фокальную функцию потерь [14]. Она позволяет сети эффективно обучаться на трудно-классифицируемых событиях (например, событие с углом пролета ШАЛ-индуцированного мюона близким к горизонтальному), даже если они редки относительно остальных событий. Для достижения максимальной чистоты отбора нейтрино-индуцированных событий, сеть штрафовалась сильнее в случае ложно-положительной идентификаций (ЛПИ) за счет введения весов для классов. Также с этой целью мы тренировали три нейронные сети, после чего усредняли их предсказания. Это позволяет уменьшить число ЛПИ благодаря принятию “коллективного” решения.

Нам удалось добиться ситуации, при которой начиная с некоторого порога классификации отсутствуют ЛПИ, в то время как сохранена большая часть экспозиции нейтрино (90%). Устанавливая требуемую чистоту отбора нейтринных событий, можно фиксировать порог классификации. Это может быть использовано для составления каталога нейтрино-индуцированных событий с фиксированной вероятностью ЛПИ.

На основе описанной выше нейронной сети, нами был разработан метод оценки потока нейтрино с наименьшей ошибкой. Суть метода заключается в следующем. Будем называть экспозицией/подавлением долю нейтрино-/ШАЛ-индуцированных событий правее порога классификации. Далее, на тестовом наборе данных данные метрики можно измерить как функции порога классификации. Эти функции можно рассматривать как некие внутренние характеристики, присущие данной нейронной сети. Тогда на интересующем нас наборе данных количество нейтрино-индуцированных событий можно оценить по следующей формуле:

$$N = \frac{n(\xi) - S(\xi)n(0)}{E(\xi) - S(\xi)}. \quad (1)$$

Здесь ξ — это порог классификации, $E(\xi)$ и $S(\xi)$ — измеренные экспозиция и подавление, соответ-

Таблица 1. Угловые разрешения углов и направления прилета нейтрино

Стандартная реконструкция			
Метрика	Азимутальный угол	Полярный угол	Направление
50% Угловое разрешение	5.42	0.53	2.62
68% Угловое разрешение	13.2	0.95	5.62
Графовая нейронная сеть			
Метрика	Азимутальный угол	Полярный угол	Направление
50% Угловое разрешение	4.16	0.53	2.10
68% Угловое разрешение	7.13	0.83	3.18

ственно, $n(\xi)$ – количество событий правее порога классификации.

Ошибка измерения $E(\xi)$ и $S(\xi)$ определяется количеством Монте-Карло событий, используемым для их оценки. В свою очередь, измеренное количество нейтринных кандидатов, $n(\xi)$, – это случайная величина, распределенная по Пуассоновскому закону. Это позволяет оценить ошибку (дисперсию) восстановления реконструированного количества нейтрино-индуцированных событий, N .

На рис. 2 приведено значение реконструированного количества нейтрино-индуцированных событий, и соответствующая ошибка как функция порога классификации. Оптимальный порог соответствует минимально возможной ошибке восстановления N . Как видно из графика, разработанный метод позволяет выделить 65 нейтрино-ин-

дуцирован-ных событий из 500000 событий с ошибкой порядка 10 событий.

4. ВОССТАНОВЛЕНИЕ УГЛА ПРИЛЕТА НЕЙТРИНО

Идентификация источников нейтрино важна для поиска их источников, в том числе в контексте многоканальной астрономии. Ниже мы описываем нейронную сеть, разработанную для восстановления угла прилета нейтрино для эксперимента Байкал-GVD.

В качестве тренировочных данных мы использовали Монте-Карло симуляцию работы детектора, описанную ранее. Дополнительно мы ограничились рассмотрением только нейтрино-индуцированных событий. Это обусловлено тем, что при взаимодействии мюонного нейтрино со средой через заряженные токи, рождаются релятивист-



Рис. 2. Архитектура нейронной сети для подавления шумовых срабатываний ОМ.

кие мюоны. Длина их свободного пробега составляет порядка километра, в силу чего подобные события называются трековыми. Они оставляют внутри экспериментальной установки четкий след, позволяющий с большой точностью реконструировать направление распространения мюона. В силу закона сохранения импульса, данное направление практически совпадает с направлением распространения изначального нейтрино.

Для очистки данных от шумовых срабатываний ОМ использовалась алгоритмическая процедура идентификации сигнальных срабатываний ОМ. Также накладывалось дополнительное условие — в рассматриваемых событиях должно быть обнаружено не менее 8 сигнальных хитов на как минимум 2х струнах. Данное условие является стандартным для алгоритмической процедуры реконструкции направления распространения нейтрино.

Для каждого события известно направление прилета нейтрино. Таким образом, нами решалась задача регрессии — реконструкция вектора направления прилета нейтрино, то есть, восстановление азимутального и полярного углов.

В отличие от предыдущих двух задач, для решения восстановления угла прилета нейтрино мы использовали графовую нейронную сеть [15]. Графовые нейронные сети позволяют работать с данными со сложной внутренней структурой, которую сложно или невозможно представить в виде последовательностей или регулярных массивов.

Для нашей задачи, ОМ представлялся в виде вершин графа, связь между которыми задается с помощью матрицы смежности. Значения, характеризующие вершины и ребра графа, обновляются нейронной сетью несколько раз, используют информацию из соседних вершин и соответствующих ребер. Для финального предсказания (направления прилета нейтрино) агрегируется информация со всего графа.

Точность реконструкции угла прилета нейтрино для разных методов приведена в табл. 1. Видно, что графовые нейронные сети позволяют добиться наилучшего углового разрешения при восстановлении направления прилета нейтрино. Стоит отметить существенное различие в порядке ошибки восстановления азимутального угла в сравнении с полярным, что можно объяснить большей разреженностью структуры кластеров в горизонтальной плоскости, чем в вертикальном направлении.

Для задач подавления шумовых срабатываний ОМ и выделения нейтрино-индуцированных событий также можно использовать графовые нейронные сети. Однако, как мы проверили, их точность сравнима с разработанными нами нейронными сетями более простого типа. Для задачи реконструкции углов, наоборот, графовые нейронные сети оказались предпочтительнее. Мы объясняем это тем, что для восстановления угла прилета

нейтрино не все сигнальные срабатывания ОМ одинаково важны, и, более того, важно их взаимное расположение. Подобную информацию возможно учесть только в графовых нейронных сетях.

5. ЗАКЛЮЧЕНИЕ

В настоящей работы мы представили первые нейронные сети, разработанные для анализа данных эксперимента Байкал-GVD. По точности, они сравнимы или превосходят стандартные алгоритмические методы реконструкции. В настоящее время идет верификация применимости разработанных методов к анализу реальных экспериментальных данных.

БЛАГОДАРНОСТИ

Данная работа была сделана при поддержке гранта Российского Научного Фонда номер 22-22-20063.

СПИСОК ЛИТЕРАТУРЫ/REFERENCES

1. *Aartsen M.G. et al.* // Science. 2013. V. 342. P. 1242856. <https://arxiv.org/abs/1311.5238>.
2. *Belolaptikov I. et al.* // Proc. PoS ICRC2021. P. 002. <https://arxiv.org/abs/2109.14344>.
3. *Allakhverdyan V.A. et al.* // Phys. Rev. D. 2023. V. 107. P. 042005. <https://arxiv.org/abs/2211.09447>.
4. *Aiello S. et al.* // Astropart. Phys. 2019. V. 111. P. 100–110. <https://arxiv.org/abs/1810.08499>.
5. *Aartsen M.G., Abbasi R., Ackermann M. et al.* // J. Phys. G. 2021. V. 48. P. 060501.
6. *Malyshkin Y. et al.* // Nucl. Instrum. Methods. Phys. Res. B. 2023. V. 1050. P. 168117.
7. *Choma N., Monti F., Gerhardt L., et al.* // <https://arxiv.org/abs/1809.06166>.
8. *Huennefeld M.* // Proc. PoS ICRC2017. P. 1057.
9. *Huennefeld M.* // EPJ Web of Conf. 2019. V. 207. P. 05005.
10. *Reck S., Guderian D., Vermarien G., Domi A.* // J. Instrum. 2021. V. 16. P. C10011. <https://arxiv.org/abs/2107.13375>.
11. *Aiello S., Albert A., Garre S.A., et al.* // J. Instrum. 2020. V. 15. P. P10005.
12. *Ronneberger O., Fischer P., Brox T.* // Proc. Intl. Conf. on Medical Image Computing and Computer-Assisted Intervention. P. 234–241.
13. *Avrorin A.D. et al.* // Proc. PoS ICRC2021 P. 1063. <https://arxiv.org/abs/2108.00208>.
14. *Lin T.-Y., Goyal P., Girshick R., He K., Doll'ar P.* // Proc. IEEE Intl. Conf. on Computer Vision. P. 2980–2988.
15. *Wang Y., Sun Y., Liu Z., Sarma S.E., Bronstein M.M., Solomon J.M.* // ACM Trans. Graph. 2019. V. 38. P. 1–12.

Application of Machine Learning Methods in the Baikal-GVD Experiment

I. V. Kharuk^{1, 2, *}, A. V. Matseiko^{1, 2}, and A. Yu. Leonov^{1, 2}

¹*Institute for Nuclear Research, Russian Academy of Sciences, Moscow, 117312 Russia*

²*Moscow Institute of Physics and Technology, Dolgoprudny, 141700 Russia*

**e-mail: ivan.kharuk@phystech.edu*

Received June 13, 2023; revised June 21, 2023; accepted July 3, 2023

Abstract—The Baikal-GVD experiment is a neutrino telescope located in Lake Baikal, Russia. As of 2022, it has an effective volume of 0.5 km³, which makes it the largest neutrino telescope in the Northern Hemisphere and the second largest in the world. This article presents an overview of machine learning methods developed to analyze data from the Baikal-GVD experiment. Specifically, we discuss neural networks developed to (1) suppress noise responses of optical modules, (2) identify neutrino-induced events and estimate their flux, and (3) recover the neutrino arrival angle. It is shown that neural networks are comparable or superior in accuracy to standard algorithmic event reconstruction procedures for similar problems.

Keywords: neutrinos, Baikal-GVD, machine learning, neural networks, data analysis