

МАТЕМАТИЧЕСКОЕ МОДЕЛИРОВАНИЕ В ЯДЕРНЫХ ТЕХНОЛОГИЯХ

УДК 520.88

МЕТОД ОПРЕДЕЛЕНИЯ ЭНЕРГИИ ГАММА-КВАНТОВ ПО ДАННЫМ АЧТ В ЭКСПЕРИМЕНТЕ TAIGA НА ОСНОВЕ АНАЛИЗА СУЩЕСТВЕННЫХ ПРИЗНАКОВ, ВЫДЕЛЯЕМЫХ С ПОМОЩЬЮ АВТОЭНКОДЕРОВ

© 2026 г. Е. О. Гресь^{а, б, *}, А. П. Крюков^б, П. А. Волчугов^б, А. П. Демичев^б, Ю. Ю. Дубенская^б, Д. П. Журов^{а, б}, С. П. Поляков^с, Е. Б. Постников^б, А. Ю. Разумов^б

^аНаучно-исследовательский институт прикладной физики ИГУ, Иркутск, 664003 Россия

^бНаучно-исследовательский институт ядерной физики им. Д.В. Скобельцына, Московский государственный университет им. М.В. Ломоносова, Москва, 119991 Россия

^сИнститут проблем информатики и автоматизации НАН РА, Ереван, 0014 Армения

*E-mail: greseo@mail.ru

Поступила в редакцию 25.07.2025 г.

После доработки 27.07.2025 г.

Принята к публикации 04.08.2025 г.

Одной из основных задач исследования гамма-источников с помощью атмосферных черенковских телескопов (АЧТ) является восстановление их энергетического спектра. В традиционном методе определения энергии гамма-квантов физические характеристики восстанавливаются путем анализа параметров Хилласа, полученных из изображений ШАЛ на АЧТ и являющимися производными статистических моментов изображения. Мы представляем альтернативный метод обработки данных АЧТ, основанный на формировании другого набора параметров – существенных признаков, извлекаемых из изображений ШАЛ с помощью нейронных сетей – автоэнкодеров. В качестве существенных признаков используются параметры латентного пространства автоэнкодеров, которые содержат информацию об изображении в сжатой форме. В данной работе рассматривается проблема восстановления энергии первичного гамма-кванта методами глубокого обучения (как прямой метод восстановления напрямую из изображений с помощью сверточных нейронных сетей, так и путем выделения существенных признаков с помощью автоэнкодера), которые сравниваются с традиционным методом на основе анализа параметров Хилласа. В качестве анализируемых данных использовались данные моделирования Монте-Карло для АЧТ проекта TAIGA. Была исследована зависимость качества восстановления энергии гамма-квантов от размерности латентного пространства. Сравнение традиционного подхода с нейросетевыми методами показало, что как сверточная сеть, так и автоэнкодеры, восстанавливают энергию гамма-квантов с точностью, которая не уступает классическому методу при малых энергиях и имеют значительно меньшую ошибку восстановления энергии при больших энергиях.

Ключевые слова: гамма-астрономия, атмосферные черенковские телескопы, методы обработки данных, нейронные сети, автоэнкодеры, восстановление энергии

DOI: 10.56304/S2079562926010136

ВВЕДЕНИЕ

Изучение космического пространства является одним из основополагающих направлений в современной физике, так как на Земле невозможно создать столь экстремальные физические условия, какие возникают в таких астрофизических объектах, как сверхновые, активные ядра галактик. На базе полученных знаний проверяются различные гипотезы о структуре Вселенной как на уровне мегамира, так и микромира.

Экспериментальные наблюдения используют множество физических сигналов: радиоволны, гравитационные волны, поток заряженных ча-

стиц, гамма-кванты. В последнее десятилетие бурное развитие получила гамма-астрономия благодаря технологическому совершенствованию и улучшению методов регистрации космических лучей. Особое внимание астрофизиков привлекает гамма-излучение очень высоких энергий (энергия более 10 ТэВ). Регистрация таких гамма-квантов осуществляется косвенным методом на поверхности Земли путем регистрации широких атмосферных ливней (ШАЛ) [1].

Одними из основных инструментов наблюдения гамма-излучения очень высоких энергий являются наземные атмосферные черенковские телескопы (АЧТ). Данные телескопы регистрируют

черенковское излучение, возникающее в процессе развития ШАЛ. С технической точки зрения АЧТ являются телескопами-рефлекторами со сферическим или параболическим зеркалом, в фокусе которого находится камера с матрицей из фотоэлектронных умножителей (ФЭУ). Существуют несколько установок с черенковскими телескопами, например, MAGIC [2], H.E.S.S. [3], TAIGA-IACT и др.

Гамма-обсерватория TAIGA, находящаяся в республике Бурятия в Тункинской долине, является уникальным экспериментом, в котором используется несколько типов детекторов, в том числе и АЧТ, которые используются для изучения потока космического и гамма-излучения высоких энергий [4]. Диаметр сегментированного зеркала АЧТ установки TAIGA, или TAIGA-IACT, равен 4.3 м, фокусное расстояние — 4.75 м. Угол обзора камеры с матрицей из 560–595 ФЭУ равен 9.7° . На данный момент введены в эксплуатацию 4 черенковских телескопа.

Наряду с созданием и совершенствованием установок астрофизики разрабатывают новые методы обработки и анализа данных, чтобы повысить точность извлечения гамма-квантов из фона, создаваемого космическим излучением, восстановления энергетического спектра и углового разрешения прихода гамма-квантов. Целью данного исследования является разработка методов обработки и анализа данных АЧТ эксперимента TAIGA. В данной работе рассматривается задача восстановления энергии гамма-квантов из изображений ШАЛ как традиционными, так и альтернативными методами, основанными на методах глубокого обучения, поскольку в последнее время данные методы находят активное применение в анализе данных АЧТ [5, 6]. В нейросетевом методе для сравнения с традиционным подходом реконструкции энергии гамма-событий была изучена сверточная нейронная сеть, которая восстанавливает энергию напрямую из изображений ШАЛ, и автоэнкодеры с различной размерностью латентного пространства.

1. ТРАДИЦИОННЫЙ ПОДХОД ВОССТАНОВЛЕНИЯ ЭНЕРГИИ

В традиционном методе процесс определения энергии можно разделить на два этапа.

Первый этап состоит в том, чтобы из изображений ШАЛ извлечь обобщающие физические характеристики. Традиционно в гамма-астрономии для получения таких характеристик используется метод, основанный на расчете центральных моментов изображения, а также некоторых геометрических и физических соображений. Полученные в результате параметры — параметры Хилласа [7] — аппроксимируют изображение

ШАЛ на матрице телескопа в виде эллипса. Базовыми параметрами являются длина малой и большой полуоси эллипса (width и length), расстояние между центром камеры, где расположен источник, и центром масс изображения (distance), угол между большой полуосью и прямой, соединяющей центр тяжести эллипса с центром системы координат (угол α), а также суммарная яркость всех пикселей матрицы камеры (size). В некоторых случаях используются дополнительные параметры, связанные с статическими моментами изображения более высокого порядка.

Для восстановления энергии гамма-квантов используется предварительное Монте-Карло моделирование ШАЛ от гамма-квантов. Восстановление энергии первичных частиц высоких энергий, регистрируемых АЧТ, выполняется с помощью линейной регрессии на основе таблиц коэффициентов, полученных из моделирования. Весь диапазон возможных значений distance разбивается на небольшие бины, после чего для событий в каждом бине определяется линейная зависимость $\lg(E) = a \lg(\text{size}) + b$. Коэффициенты линейной зависимости сохраняются в таблицу для дальнейшего применения и предсказания.

2. МЕТОДЫ ГЛУБОКОГО ОБУЧЕНИЯ ДЛЯ ВОССТАНОВЛЕНИЯ ЭНЕРГИИ

Одними из альтернативных методов восстановления энергии являются методы глубокого обучения [8]. Нейронные сети представляют собой сильно упрощенную математическую модель функционирования нейронов в мозге. В каждом отдельном нейроне взвешенные сигналы $w_i x_i$, поступающие от предшествующих нейронов, складываются, затем на основе этой суммы генерирует выходной сигнал, используя нелинейную функцию активации $f(\sum w_i x_i + b)$. Многослойное объединение нейронов в виде графа формирует нейронную сеть. В процессе обучения сетей происходит настройка весов w_i между нейронами с помощью метода обратного распространения ошибки, который является аналогом градиентного спуска.

Сверточные нейронные сети (CNN) были разработаны для обработки двумерных изображений. Сверточные слои анализируют небольшие области изображений с помощью дополнительных весовых матриц (фильтров или ядер) с помощью операции свертки. В результате выделяются общие структуры и признаки в изображениях. Благодаря этому CNN является одним из лучших способов для анализа изображений.

Структура CNN-регрессора, используемая в данной работе, представлена на рис. 1а. Функцией активации между скрытыми слоями являлась функция ReLU, на выходном слое — линейная функция активации. В задаче восстановле-




Рис. 1. Схематическое представление нейронных сетей по определению энергии гамма-квантов, регистрируемых экспериментом TAIGA-IAC. (а) Структура сверточной нейронной сети, определяющая энергию напрямую из изображений (CNN-регрессор). (б) Структура автоэнкодера с переменным значением латентного пространства N_{dim} , из которого после обучения автоэнкодера полносвязанная нейросеть (преобразователь) восстанавливает энергию.

ния энергии обучение CNN-регрессора длилось 35 эпох.

2.1. Автоэнкодеры

Автоэнкодер (АЕ) [9] — это нейронная сеть, которая сначала кодирует входной сигнал в некоторый вектор $h = g(y)$ в пространстве скрытых признаков, а затем из этого вектора снова разворачивает (декодирует) данные в другой вектор $y_{\text{reco}} = r(h)$. В процессе обучения минимизируется функционал ошибки $L(y, r(g(y)))$. Отличительной чертой автоэнкодеров является то, что число нейронов на входе y и на выходе y_{reco} одинаковы, а тренировка АЕ является обучением без учителя (т.е. не требуется от человека дополнительной информации в виде меток). В зависимости от поставленной задачи меняется структура или функционал ошибки L , отчего АЕ разделяют на следующие виды: полносвязанный АЕ, вариационный АЕ и др.

Главной особенностью автоэнкодеров является наличие “узкого горлышка” — латентного пространства, размерность которого намного меньше, чем размерность самих данных. В процессе обучения АЕ сжимает входные данные в компактное представление в латентном пространстве признаков. Данный подход кодировки похож на подход, который используется в традиционном методе определения энергии, т.е. выделение некоторых существенных признаков (параметры Хилла-са), содержащих необходимую информацию о физическом процессе, и извлечение требуемой информации (энергии) из этих признаков. В отличие от традиционного подхода, размерность латентного пространства АЕ может быть легко изменена. Следовательно, варьированием размерности этого пространства возможно найти оптимальное ко-

личество признаков, чтобы наилучшим образом восстанавливать исходные физические параметры гамма-квантов.

Поскольку в качестве входных данных с установки TAIGA-IAC мы получаем изображения ШАЛ, то поиск оптимального размера латентного пространства с последующим извлечением энергии в данной работе происходил с помощью сверточных автоэнкодеров (рис. 1б). Были рассмотрены следующие значения размерности латентного пространства: 3, 6, 9, 12 и 18. Большее значение размерности мы решили не исследовать, так как в изображениях ШАЛ от гамма-квантов на матрице 560 пикселей в большинстве случаев число ненулевых пикселей не превосходило 28. Автоэнкодеры были реализованы на языке Python с помощью библиотеки Tensorflow и Keras.

Для каждого значения размерности автоэнкодер обучался заново. В данном эксперименте функция активации между скрытыми слоями являлась функция LeakyReLU, на выходном слое — линейная функция активации. Функционалом ошибки при тренировке являлась среднеквадратичная ошибка между истинным и восстановленным изображением. Само обучение происходило в течение 100 эпох.

Из существенных признаков, полученных автоэнкодером, восстановление физических параметров проводилось с помощью полносвязанной нейронной сети (см. рис. 1б) (в дальнейшем — преобразователь). Применялась функция ReLU в качестве функции активации между скрытыми слоями, функционалом ошибки являлась также среднеквадратичная ошибка между истинным и восстановленным значением энергии. Обучение преобразователя длилось не более, чем 25 эпох.

Стоит отметить, что преобразователь возвращал десятичный логарифм энергии из-за широкого диапазона энергий обучающих и тестовых данных. Использование логарифма позволило уменьшить погрешность определения энергии примерно на 10% на всем энергетическом диапазоне по сравнению с восстановлением энергии без логарифма.

3. ОБУЧАЮЩИЕ ДАННЫЕ

Хорошо известно, что исходные данные играют ключевую роль в методе нейронных сетей. Это связано с тем, что именно на примерах в обучающей выборке нейронная сеть учиться обобщать и аппроксимировать данные. Таким образом, обучающая выборка должна быть достаточно большой и репрезентативной. Для этого была сформирована обучающая выборка, включающая в себя смоделированные по Монте-Карло (МС) гамма-события, приходящие с зенитными углами 30° – 40° (соответствует углу наблюдения Крабовидной туманности в месте, где расположены телескопы). Спектр выборки имел степенной закон со спектральным индексом, равном -1 , в диапазоне энергий 2 – 1000 ТэВ. Также источник гамма-излучения был смещен на 1.22° на камере телескопа в произвольном направлении для моделирования режима наведения Wobble [10], что используется и в эксперименте.

Генерация гамма-изображений осуществлялась с использованием программного обеспечения CORSIKA [11], а также специализированных инструментов для моделирования отклика телескопа TAIGA-IACT [12]. В итоге, в обучающей выборке было 166 тысяч изображений ШАЛ.

Для обучения нейросетевых моделей была проведена следующая подготовка данных: очистка изображений от шума, приведение источника гамма-событий к центру камеры в связи с наблюдением в режиме Wobble, преобразование изображения к прямоугольному виду из-за первоначальной гексагональной структуры изображений АЧТ и логарифмическое масштабирование амплитуд пикселей. Подробное описание подготовки данных представлено в работе [13]. Необходимо отметить, что и для классического подхода определения энергии также проводится подготовка данных, которая включает в себя очистку изображений и приведение изображений к центру камеры из-за режима наблюдения Wobble.

4. РЕЗУЛЬТАТЫ

Поиск оптимального размера латентного пространства АЕ и оценка точности восстановления энергии проводились на тестовой выборке, состоящей из 83 тысяч МС-изображений ШАЛ от гамма-квантов. Статистические характеристики

тестовой выборки соответствовали статистическим характеристикам обучающей выборки.

4.1. Оценка качества восстановления изображений автоэнкодером

При обучении АЕ и реконструкции изображений необходимо было понять, при каком числе существенных признаков (размерность латентного пространства АЕ) потери информации о гамма-излучении незначительны и восстановленные изображения минимально отличаются друг от первоначальных. Метрикой оценки была выбрана средняя абсолютная ошибка (MAE), рассчитанная между восстановленным и истинным изображением.

На рис. 2 продемонстрировано распределение MAE для автоэнкодеров с различным числом латентных признаков и получены медианные значения этих распределений. По результатам хорошо видно, как медиана MAE мало меняется, начиная с 6 латентных признаков, что сигнализирует о том, что 6–9 признаков может быть достаточно, чтобы сжать информацию о гамма-излучении, регистрируемом TAIGA-IACT, с незначительными потерями информации. Также заметно, что даже при 18 латентных признаках наблюдаются большие ошибки восстановления, характерные для гамма-событий с большими энергиями. Данное явление связано с тем, что событий с энергиями 500 ТэВ на два порядка меньше, чем событий с энергией 5 ТэВ, отчего автоэнкодеры хуже обучены восстанавливать изображения высокоэнергетичных гамма-квантов.

Дополнительно, для оценки качества реконструкции изображений проводилось сравнение первоначальных параметров Хилласа и параметров Хилласа, вычисленных из восстановленных изображений. В табл. 1 представлены среднеквадратичные ошибки распределения относительных погрешностей для разной размерности латентного пространства автоэнкодеров. Полученные значения демонстрируют хорошее качество восстановления (около 10%) при 9 признаках и более. Огромные флуктуации угла α связаны с тем, что для гамма-квантов характерны малые углы (примерно меньше 10°), отчего относительная погрешность вблизи 0° становится большой (около 100%). При рассмотрении ошибки $\alpha_{\text{reco}} - \alpha_{\text{true}}$ смещение такого распределения уменьшается от 1.6° до 0.5° , среднеквадратичная ошибка — от 6.7° до 4.5° соответственно с увеличением латентного пространства АЕ.

Таким образом, представленные выше результаты говорят, что 6–9 признаков достаточно для хорошего сжатия данных.




Рис. 2. Слева: распределение средней абсолютной ошибки (MAE), рассчитанной между первоначальными и восстановленными изображениями. Справа представлена зависимость MAE от энергии при восстановлении событий автоэнкодером с размерностью латентного пространства, равном 9.

4.2. Оценка определения энергии

При оценке качества определения энергии традиционными методами через параметры Хилласа и с помощью нейросетевых моделей весь смоделированный энергетический диапазон 2–1000 ТэВ был разбит на интервалы с равным числом событий. Для каждого интервала была рассчитана относительная ошибка между восстановленным и истинной энергией, а также вычислены смещение и флуктуация полученной ошибки. Результаты представлены на рис. 3. Из графиков видно, что 6 латентных признаков все еще недостаточно для лучшего восстановления энергии через автоэнкодеры. Сравнение всех методов в основном диапазоне энергий 5–300 ТэВ показывает, что

в традиционном методе возникают сильные неоднородные смещения и флуктуации в определении энергии. Нейросетевой метод, основанный на автоэнкодерах, не обладает столь сильными перепадами, отчего на указанном энергетическом диапазоне погрешности восстановления энергии составляют 21–25% со смещениями энергий до 10%. Лучший результат был получен CNN – флуктуации составляют 19–20% со смещениями энергий до 8%, что связано с тем, что у CNN блок со сверточными слоями является анализатором изображений наподобие энкодера, выделяющего 256 параметров для определения энергии, что намного больше, чем скрытых признаков у рассмотренных АЕ. Однако использование такого количества па-

Таблица 1. Среднеквадратичные ошибки распределения относительных погрешностей между первоначальными параметрами Хилласа и параметрами, вычисленными из изображений, восстановленных автоэнкодерами разной размерности латентного пространства

Число параметров латентного пространства АЕ	3	6	9	12	18
Расстояние	8.81%	8.15%	7.90%	7.83%	7.76%
Длина	13.65%	11.07%	9.75%	8.50%	9.83%
Ширина	15.82%	13.69%	12.15%	11.48%	10.72%
lg (размер)	4.69%	3.15%	2.59%	2.63%	2.33%




Рис. 3. Результаты восстановления энергии первичных гамма-квантов традиционным и нейросетевыми методами (CNN и автоэнкодеры). (а) Ожидаемое смещение при восстановлении энергии, определяемое через среднее значение распределений относительных погрешностей в разных энергетических диапазонах. (б) Флуктуации относительных погрешностей относительно среднего, определяемое как медианное значение абсолютных погрешностей.

раметров сильно затруднит их использование в будущем мультимодальном анализе, когда наряду с АЧТ будут включены данные с TAIGA-HiSCORE.

ЗАКЛЮЧЕНИЕ

В работе решалась одна из важных задач гамма-астрономии — определение энергии гамма-квантов. Было сравнено несколько методов по восстановлению энергии: традиционный подход, основанный на линейной регрессии энергии и нескольких параметров Хилласа, и методы глубокого обучения. Особое внимание уделялось нейросетевому методу, базирующемуся на восстановлении энергии из латентного пространства автоэнкодеров.

В результате было установлено, что латентное пространство автоэнкодеров может быть использовано для решения поставленной задачи. Было показано, что для данных TAIGA-IACST оптимальный размер латентного пространства равен 9. Дальнейшее увеличение числа латентных признаков не дает значительного улучшения результата. Ошибка восстановления энергии в этом случае равна 20–25%, смещение составляет не более 10% для основного диапазона энергий (5–300 ТэВ). Краевой эффект в области больших энергий (500–1000 ТэВ) обусловлен малым числом событий на большой диапазон энергий.

Для обычных нейросетевых методов, которые направлены на восстановление данных напрямую из изображений ШАЛ, результат немного лучше — ошибка восстановления примерно равна 20% на всем диапазоне, в то время как смещение — не более 8%. При сравнении с результатами обычных нейросетевых методов метод с использованием автоэнкодеров выглядит перспектив-

ным. Пространство латентных параметров будет использоваться для выделения гамма-квантов от адронного фона и определения и других параметров ШАЛ, а также будет применяться в объединении данных АЧТ с данными других установки TAIGA для мультимодального анализа. Также, за счет модульности АЕ для извлечения других физических параметров достаточно изменить преобразователь вместо полного переучивания целой сверточной нейронной сети, что является менее ресурсозатратным процессом.

БЛАГОДАРНОСТИ

Исследование выполнено в рамках государственного задания Московского государственного университета имени М.В. Ломоносова с использованием оборудования, предоставленного по Программе развития МГУ, и данных, полученных на уникальной экспериментальной установке TAIGA.

ФИНАНСИРОВАНИЕ

Исследование выполнено при поддержке Российского научного фонда (грант № 24-11-00136).

СПИСОК ЛИТЕРАТУРЫ/REFERENCES

1. *Degrang B., Fontaine G.* // C. R. Acad. Sci., Ser. IV. 2015. V. 16 (6–7). P. 587–599.
2. *Aharonian F., Akhperjanian A.G., Bazer-Bachi A.R., et al.* // Astron. Astrophys. 2006. V. 457 (3). P. 899–915.
3. *Baixeras C., Bastieri D., Bigongiari C., et al.* // Nucl. Instrum. Methods Phys. Res., Sect. A. 2004. V. 518 (1–2). P. 188–192.

4. Budnev N., Astapov I., Bezyazeev P., et al. // Nucl. Instrum. Methods Phys. Res., Sect. A. 2022. V. 1039. P. 167047.
5. Demichev A., Kryukov A. // Astron. Comput. 2024. V. 46. P. 100793.
6. Kryukov A.P., Polyakov S.P., Vlaskina A.A., et al. // Moscow Univ. Phys. Bull. 2023. V. 78 (Suppl. 1). P. S37–S44.
7. Hillas A.M. // Proc. 19th Int. Cosmic Ray Conf. (ICRC19). 1985. V. 3. P. 445.
8. LeCun Y., Bengio Y., Hinton G. // Nature. 2015. V. 521. P. 436–444.
9. Rumerhart D.E., Hinton G.E., Williams R.J. // Nature. 1986. V. 323. P. 533–536.
10. Fomin V.P., Stepanian A.A., Lamb R.C., et al. // Astropart. Phys. 1994. V. 2 (2). P. 137–150.
11. Heck D., Knapp J., Capdevielle J.N., et al. // Report FZKA-6019. 1998. Forschungszentrum Karlsruhe.
12. Postnikov E.B., Astapov I.I., Bezyazeev P.A., et al. // Bull. Russ. Acad. Sci.: Phys. 2019. V. 83. P. 955–958.
13. Gres E.O., Kryukov A.P., Volchugov P.A., et al. // Moscow Univ. Phys. Bull. 2024. V. 79 (Suppl. 2). P. S622–S629.

Gamma-Ray Energy Reconstruction from TAIGA-IACT Data Based on Analysis of Autoencoder-Derived Essential Features

E. O. Gres^{1, 2, *}, A. P. Kryukov², P. A. Volchugov², A. P. Demichev², J. J. Dubenskaya², D. P. Zhurov^{1, 2},
S. P. Polyakov³, E. B. Postnikov², and A. J. Razumov²

¹Research Institute of Applied Physics of Irkutsk State University, Irkutsk, 664003 Russia

²Skobeltsyn Institute of Nuclear Physics, Lomonosov Moscow State University, Moscow, 119991 Russia

³Institute for Informatics and Automation Problems of the National Academy of Science
of the Republic of Armenia, Yerevan, 0014 Republic of Armenia

*e-mail: greseo@mail.ru

Received July 25, 2025; revised July 27, 2025; accepted August 4, 2025

Abstract—One of the main tasks in studying gamma-ray sources with Imaging Atmospheric Cherenkov telescopes (IACTs) is the energy spectrum reconstruction. In the conventional method of gamma-ray energy reconstruction, physical characteristics are determined by analyzing the Hillas parameters, which are derivatives of statistical moments calculated from IACT-recorded extensive air shower (EAS) images. We present an alternative IACT data processing method that uses a different set of parameters called essential features, which are extracted from EAS images using an autoencoder neural network. As essential features it is proposed to use the parameters from the latent space of autoencoders, which contain information about the image in compressed form. This paper investigates the traditional gamma-ray energy reconstruction approach and compares it with deep learning methods (both direct energy reconstruction using convolutional neural networks and essential features extraction using an autoencoder). The study utilized TAIGA-IACT Monte Carlo simulations as a dataset. The dependence of the quality of gamma-ray energy reconstruction on the latent space dimensionality was investigated. Comparison between the conventional approach and deep learning methods demonstrated that both convolutional networks and autoencoders reconstruct gamma-ray energies with accuracy comparable to the conventional method at low energies. At high energies, deep learning methods demonstrate significantly lower energy reconstruction errors compared to the conventional approach.

Ключевые слова: gamma astronomy, imaging atmospheric Cherenkov telescope, data processing methods, neural networks, autoencoders, energy reconstruction