

РЕШЕНИЕ ЗАДАЧИ МНОГОМЕТОЧНОЙ КЛАССИФИКАЦИИ ДЛЯ ИДЕНТИФИКАЦИИ РАДИОНУКЛИДОВ

СКРЫПНИК А.И., ФЕДОРЧЕНКО Д.В.,

ХАЖМУРАДОВ М.А.

Описывается определение изотопного состава радиоактивных источников, состоящих из одного до пяти нуклидов (^{57}Co , ^{137}Cs , ^{131}I , ^{133}Ba и ^{241}Am), по спектрам их гамма-излучения. Для получения спектров используется программа, разработанная на базе библиотек Geant4. Задача идентификации нуклидов рассматривается как задача многометочной классификации. Поставленная задача преобразовывается в набор задач однометочной классификации, для решения которых используются такие методы классификации, как метод k ближайших соседей, наивный байесовский классификатор, метод опорных векторов и деревья решений.

Ключевые слова: идентификация нуклидов, многометочная классификация, метод k ближайших соседей, наивный байесовский классификатор, метод опорных векторов и деревья решений.

Key words: nuclide identification, multi-label classification, k-nearest neighbors method, naive Bayes classifier, support vector machines and decision trees.

1. Введение

Для идентификации радионуклидов по гамма-спектрам, как правило, используются различные алгоритмы, основанные на поиске пиков, оценке их местоположения и параметров [1, 2]. Однако часто возникает необходимость детектирования слабого сигнала либо использования спектрометров с низким энергетическим разрешением. В таких ситуациях не всегда работают стандартные алгоритмы. Все больший интерес проявляют к себе различные алгоритмы машинного обучения (нейронные сети, например) [3, 4]. Они дают возможность идентифицировать радионуклиды по гамма-спектру, анализируя весь спектр.

В случае исследования радиоактивного источника, состоящего из одного изотопа, его идентификация в терминах машинного обучения является задачей однометочной классификации (может быть бинарной или многоклассовой). Идея многоклассовой классификации заключается в том, что существует много классов, однако каждый объект может принадлежать лишь одному классу [5]. На практике редко встречаются такие ситуации. При мониторинге территорий, которые загрязнены естественными и техногенными радионуклидами, контроле над несанкционированным перемещением радиоактивных веществ и

решении многих других задач, связанных с необходимостью мгновенной идентификации радиоактивных источников, в источниках содержится более одного изотопа. Описанная проблема идентификации нуклидов относится к многометочной классификации. В задачах данного типа объект может относиться сразу к нескольким классам [5]. Основное различие между данными видами классификации состоит в результате на выходе классификатора. В первом случае классификатор возвращает одно значение, а во втором – вектор значений [6].

Существует два основных подхода к решению задачи многометочной классификации: использование методов, которые преобразуют задачу в набор более простых задач однометочной классификации, и методов, которые специально адаптированы для решения задач классификации этого типа [7]. В данной работе используется первый подход.

Например, если необходимо определить изотопный состав радиоактивного источника, состоящего из цезия и йода, то поставленную задачу с помощью одного из методов преобразования можно разделить на две части. Сначала необходимо построить классификатор, который определит наличие цезия в составе источника. Далее построить классификатор для определения наличия йода в радиоактивном источнике. При этом можно использовать любой классификатор, способный решить задачу бинарной классификации: наивный байесовский классификатор, дерево решений, метод k ближайших соседей, нейронную сеть, метод опорных векторов и т.д.

В работе [8] было исследовано применение искусственных нейронных сетей для идентификации радионуклидов по гамма-спектрам. Была создана многослойная сеть прямого распространения, которая обучалась с помощью алгоритма обратного распространения ошибки.

Данная работа посвящена определению изотопного состава радиоактивных источников по спектрам их излучения с помощью метода k ближайших соседей, наивного байесовского классификатора, метода опорных векторов и деревьев решений.

2. Методы преобразования задачи многометочной классификации в набор задач однометочной классификации

Преобразование задачи многометочной классификации к набору задач однометочной классификации осуществлялось тремя различными методами: бинарной релевантности (binary relevance) [9], булеана меток (label powerset) [9] и цепочек классификаторов (classifier chains) [10]. Самым простым и наиболее популярным является метод бинарной релевантности. С его помо-

щью на основе первоначального набора данных (в нашем случае это спектры излучения радиоактивных источников) создается k наборов данных, где k – количество классов (в данной задаче k – количество изотопов, которые могут входить в состав радиоактивного источника). Каждый набор данных содержит все объекты (спектры), содержащиеся в первоначальном наборе. Однако каждый из них используется для обучения двоичного классификатора в целях предсказания существования лишь одного из радионуклидов, а не всего изотопного состава.

Рассмотрим применение данного метода для задачи классификации радиоактивного источника, в состав которого могут входить пять изотопов: ^{57}Co , ^{137}Cs , ^{131}I , ^{133}Ba и ^{241}Am . В табл. 1 представлен пример небольшого набора данных задачи многометочной классификации; x_1, x_2, x_3, x_4 – спектры гамма-излучения, ^{57}Co , ^{137}Cs , ^{131}I , ^{133}Ba и ^{241}Am обозначают классы; 0 и 1 – метки классов, которые указывают на отсутствие либо наличие изотопа соответственно. Табл. 2 демонстрирует соответствующее преобразование набора данных.

Таблица 1. Набор данных задачи многометочной классификации

X	Co	Cs	I	Ba	Am
x_1	1	0	0	1	0
x_2	0	1	1	1	1
x_3	0	1	0	1	0
x_4	1	0	1	0	1

Таблица 2. Преобразование набора данных из табл. 1 методом бинарной релевантности

X	Co	X	Cs	X	I	X	Ba	X	Am
x_1	1	x_1	0	x_1	0	x_1	1	x_1	0
x_2	0	x_2	1	x_2	1	x_2	1	x_2	1
x_3	0	x_3	1	x_3	0	x_3	1	x_3	0
x_4	1	x_4	0	x_4	1	x_4	0	x_4	1

Метод булеана меток заключается в создании 2^k новых классов, где k – количество классов. Этот подход достаточно эффективен, однако эффективность может падать с ростом количества классов, что в нашем случае ограничивает возможное количество нуклидов. Преобразование набора данных для этого метода приведено в табл. 3.

Таблица 3. Преобразование набора данных из табл. 1 методом булеана меток

X	2^k классов
x_1	1 0 0 1 0
x_2	0 1 1 1 1
x_3	0 1 0 1 0
x_4	1 0 1 0 1

Метод цепочек классификаторов похож на метод бинарной релевантности, однако он включает предыдущие предсказания в признаки объектов (табл. 4).

3. Методы классификации

Задача многометочной классификации, преобразованная в задачу или набор задач однометочной классификации, может быть решена с помощью стандартных алгоритмов однометочной классификации.

3.1. Метод k ближайших соседей. Алгоритм k ближайших соседей является одним из наиболее простых алгоритмов машинного обучения. Основной принцип его работы заключается в запоминании данных, которые входят в обучающий набор. Для прогнозирования принадлежности новой точки данных к какому-либо классу необходимо определить k точек обучающего набора, которые находятся ближе всего. Таким образом, важным шагом является выбор числа ближайших соседей k .

Достоинство алгоритма k ближайших соседей заключается в том, что он не требует большого количества настроек. Одним из основных недостатков является высокая вероятность переобучения при работе с разреженными наборами данных.

3.2. Наивный байесовский классификатор. Данный метод классификации основан на применении теоремы Байеса с предположением о том, что признаки, описывающие объекты задачи, являются статистически независимыми. Алгоритм дает хороший результат в задачах, в которых признаки являются действительно независимыми. Существует три разновидности наивного байесовского классификатора: Гауссов, многомерный и мультиномиальный. В большинстве случаев два последних используются в задачах классификации текста.

3.3. Метод опорных векторов. Основная идея метода заключается в нахождении разделяющей поверхности, которая отделяет классы друг от друга. Разделяющая поверхность может быть как линейной, так и нелинейной. Для того чтобы установить вид разделяющей поверхности, необходимо выбрать тип ядра, которое может быть линейным, полиномиальным либо радиальным. Для определения эффективной модели нужно подобрать оптимальные значения параметров C и Gamma . Первый управляет размытием отступов, а второй – размером ядра.

Преимущество данного метода заключается в возможности приспособить его к различным типам данных. Однако чтобы получить эффективную модель, необходимо тщательно подобрать параметр размытия.

Таблица 4. Преобразование набора данных из табл. 1 методом цепочек классификаторов

X	Co	X	Co	Cs	X	Co	Cs	I	X	Co	Cs	I	Ba	X	Co	Cs	I	Ba	Am
x ₁	1	x ₁	1	0	x ₁	1	0	0	x ₁	1	0	0	1	x ₁	1	0	0	1	0
x ₂	0	x ₂	0	1	x ₂	0	1	1	x ₂	0	1	1	1	x ₂	0	1	1	1	1
x ₃	0	x ₃	0	1	x ₃	0	1	0	x ₃	0	1	0	1	x ₃	0	1	0	1	0
x ₄	1	x ₄	1	0	x ₄	1	0	1	x ₄	1	0	1	0	x ₄	1	0	1	0	1

3.4. Деревья решений. Основной принцип работы метода, основанного на дереве решений, состоит в разбиении данных на подмножества с помощью принятия решений. Модель можно представить в виде дерева, которое состоит из корня, узлов и листьев. Корнем называется верхний узел, который содержит весь набор данных, подлежащих классификации. В узлах происходит деление на ветви. Листьями называются конечные узлы. Модели, основанные на деревьях решений легко поддаются переобучению. Данный процесс происходит, когда дерево становится слишком глубоким и каждая точка обучающего набора данных верно классифицируется. Такое дерево имеет плохую обобщающую способность. Переобучение можно предотвратить с помощью обрезки дерева.

4. Метрика качества модели

Метрики качества модели в задачах многометочной классификации немного отличаются от метрик в стандартных задачах классификации. В данном случае новый объект может быть не только верно либо неверно классифицирован, он может быть частично верно классифицирован [11]. Таким образом, в некоторых случаях может быть правильно определена лишь часть нуклидов, содержащихся в источнике.

Одной из самых распространенных метрик качества является правильность, которая представляет долю верно классифицированных объектов от общего числа объектов [12, 13]. В задачах многометочной классификации объект считается классифицированным верно, если все метки, предсказанные для данного объекта, полностью совпадают с истинными метками. Для обозначения такой метрики в англоязычной литературе используется термин 'subset accuracy' либо '0/1 subset accuracy' [11]. Правильность в данной задаче представляет собой долю верно классифицированных радиоактивных источников от общего количества радиоактивных источников. Радиоактивный источник является правильно классифицированным, если в нем правильно определен весь изотопный состав.

Для оценки качества модели многометочной классификации используется метрика Хэмминга [12, 13]. Она показывает, сколько меток классов из общего количества спрогнозированы неверно. В данной метрике учитываются ошибки и 1-го и 2-го рода, так как спрогнозированные метки могут оказаться как ложно положительными, так и ложно отрицательными.

Оценить качество модели в задачах однометочной классификации также можно, определив точность и полноту. Данные метрики используются также в задачах многометочной классификации [12, 13]. Точность показывает, сколько из предсказанных положительных меток классов являются истинно положительными:

$$\text{точность} = \frac{tp}{tp + fp}$$

В уравнении tp – количество истинно положительных меток классов; fp – количество ложноположительных меток классов.

Полнота показывает, сколько из истинных положительных меток предсказано как положительные:

$$\text{полнота} = \frac{tp}{tp + fn}$$

где fn – количество ложно отрицательных меток классов.

В задачах многометочной классификации точность и полноту можно рассчитывать независимо для каждой метки. Существует несколько способов для объединения результатов. Первый способ - можно рассчитать точность и полноту сразу для всего набора данных. Второй способ заключается в расчете данных метрик для каждого класса в отдельности и последующем их усреднении по всем классам. Третий способ состоит в расчете точности и полноты для каждого объекта, в данном случае радиоактивного источника, и усреднении результатов по всем объектам.

5. Модель

Для определения изотопного состава радиоактивных источников в качестве набора данных было взято 500 спектров гамма-излучения источников. В состав каждого из источников вхо-

дили от одного до пяти нуклидов, а именно: ^{57}Co , ^{137}Cs , ^{131}I , ^{133}Ba и ^{241}Am . Данный выбор изотопов связан с использованием достаточно тонкого детектора CdZnTe (табл. 5) для получения гамма-спектров в компьютерных экспериментах. Преимущество подобных детекторов заключается в их дешевизне и возможности работать при комнатной температуре.

Таблица 5. Характеристики детектора

Материал детектора	CdZnTe
Размеры	6×6×3 мм
Произведение подвижности на время жизни электронов	$3 \times 10^{-3} \text{ см}^2/\text{В}$
Произведение подвижности на время жизни дырок	$3 \times 10^{-4} \text{ см}^2/\text{В}$

Функции отклика детектора CdZnTe на излучение ^{57}Co , ^{137}Cs , ^{131}I , ^{133}Ba и ^{241}Am (рис. 1) были рассчитаны с помощью программы, разработанной на основе пакета библиотек для моделирования прохождения элементарных частиц через вещество Geant4 [14, 15]. Данная программа была разработана и верифицирована ранее [16]. Полученные спектры были нормированы на единицу.

Функции отклика для индивидуальных изотопов были использованы для получения 500 функций отклика CdZnTe детектора для смешанных радиоактивных источников.

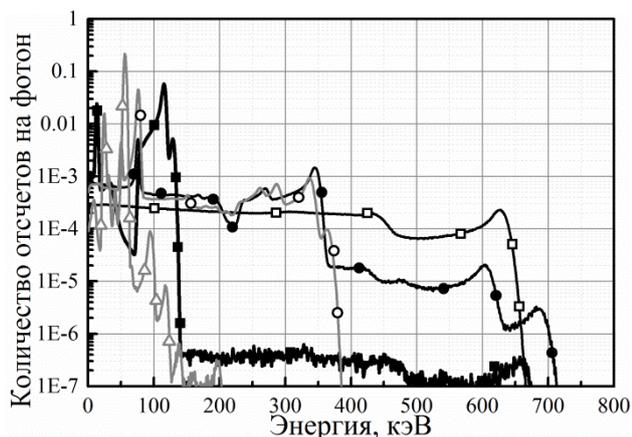


Рис. 1. Гамма-спектры (^{57}Co – черные квадраты, ^{137}Cs – белые квадраты, ^{131}I – черные кружки, ^{133}Ba – белые кружки, ^{241}Am – белые треугольники)

Набор данных из 500 гамма-спектров был разбит на обучающий и проверочный наборы размерами 350 и 150 спектров соответственно. Гамма-спектры в наборах представляют собой объекты. Все гамма-спектры были разделены на 40 каналов, значения в которых являются признаками

объектов. Все нуклиды, которые предположительно могут содержаться в радиоактивных источниках, представляют собой классы. ^{57}Co , ^{137}Cs , ^{131}I , ^{133}Ba и ^{241}Am являются метками соответствующих классов.

Для определения изотопного состава радиоактивных источников были использованы различные методы классификации: метод k ближайших соседей, наивный байесовский классификатор, метод опорных векторов и деревья решений. Перед применением каждого из алгоритмов задача многометочной классификации была преобразована в набор задач однокметочной классификации с помощью методов бинарной релевантности, булеана меток и цепочек классификаторов. Все алгоритмы были реализованы на языке программирования Python с помощью библиотек scikit-learn [17] and scikit-multilearn [18].

6. Результаты

Для оптимизации работы алгоритмов необходимо выбрать эффективные параметры моделей. Поиск оптимальных значений параметров является одним из ключевых моментов в построении модели. Для определения оптимальных значений параметров необходимо сначала разделить исходный набор данных на обучающий, проверочный и тестовый. Обучающий набор используется для построения и обучения модели. С помощью проверочного набора определяют оптимальные значения параметров модели. Тестовый набор применяется для оценки качества модели. Однако, так как данный метод слишком чувствителен к правильности разбиения данных, в работе для поиска эффективных параметров была использована перекрестная проверка, а именно самая распространенная k-блочная перекрестная проверка. Работа данной методики заключается в обучении модели k раз на (k-1) подвыборках. Каждый раз проверка модели осуществляется на оставшейся подвыборке. Таким образом, исходный набор данных был разделен только на обучающий и тестовый. Тестовый набор как обычно был использован только для оценки качества конечной модели. К обучающему набору была применена 5-блочная перекрестная проверка, с помощью которой определены оптимальные значения параметров модели (табл. 6). Для моделей, основанных на методе k ближайших соседей, были определены оптимальные значения количества ближайших соседей. В моделях, построенных на основе опорных векторов, были выбраны наиболее эффективные ядра и параметры C и Gamma.

Необходимо заметить, что в случае использования линейного ядра изменяется только параметр C. Для моделей, основанных на деревьях решений, были определены оптимальные значения следующих параметров: максимального количества признаков, по которым ищется разбиение, и максимальной глубины дерева.

Для сравнения качества алгоритмов классификации были применены такие метрики качества как правильность, метрика Хэмминга, точность и полнота. Правильность существенно зависит от соотношения классов и не представляет ценности в задачах с неравными классами. Так как в наборе данных каждый нуклид представлен при-

мерно в одинаковом процентном соотношении, правильность рассматривается как одна из основных метрик в данной задаче классификации. Как было указано выше, важной метрикой качества алгоритма в задачах многометочной классификации является метрика Хэмминга. Она указывает на то, как часто метка класса была спрогнозирована неправильно, т.е. как часто было спрогнозировано неправильно наличие или отсутствие ^{57}Co , ^{137}Cs , ^{131}I , ^{133}Ba и ^{241}Am в радиоактивных источниках. Точность и полнота также часто используются для сравнения качества алгоритмов классификации данного типа.

Таблица 6. Оптимальные значения параметров моделей

Алгоритм классификации	Параметры модели	Метод преобразования задачи	Оптимальные значения параметров
Метод к ближайших соседей	Количество ближайших соседей	Бинарная релевантность	3
		Булеан меток	3
		Цепочки классификаторов	3
Метод опорных векторов	Ядро; C; Gamma	Бинарная релевантность	Линейное; 100; 0.001
		Булеан меток	Полиномиальное; 0.001; 100
		Цепочки классификаторов	Линейное; 100; 0.001
Дерево решений	Максимальное количество признаков; максимальная глубина дерева	Бинарная релевантность	39; 3
		Булеан меток	33; 5
		Цепочки классификаторов	38; 2

На рис. 2-5 представлены метрики качества разных классификационных моделей. Заглавными буквами обозначены использованные методы классификации: А – метод к ближайших соседей, Б – наивный байесовский классификатор, В – метод опорных векторов, Г – дерево решений. Штриховка означает, что задача многометочной классификации была преобразована в набор задач однокметочной классификации с помощью метода бинарной релевантности. Серым и черным цветом показано, что преобразование задачи было проведено с помощью методов булеана меток и цепочек классификаторов соответственно.

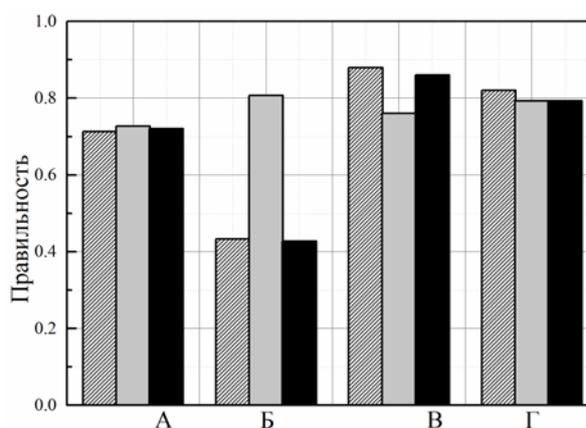


Рис. 2. Сравнение правильности алгоритмов

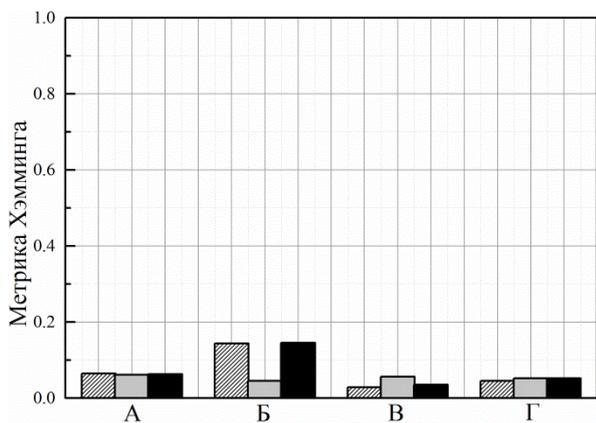


Рис. 3. Сравнение метрики Хэмминга для алгоритмов

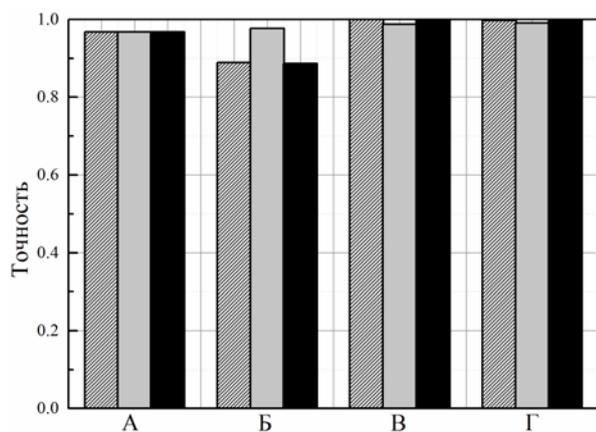


Рис. 4. Сравнение точности алгоритмов

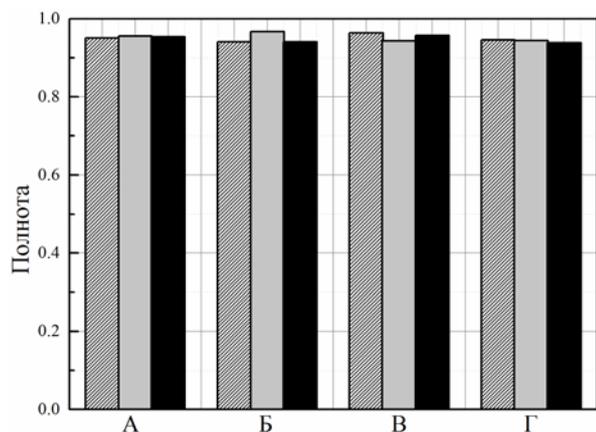


Рис. 5. Сравнение полноты алгоритмов

Как видно из рис. 2 наилучшие правильности, которые составляют 0.88 и 0.86, имеют модели, основанные на методе опорных векторов. В данном случае задача многометочной классификации была преобразована с помощью методов бинарной релевантности и цепочек классификаторов. Правильность данной модели с преобразованием задачи методом булеана меток составляет 0.76. Достаточно хорошую правильность, приблизительно 0.8, имеют модели, основанные на деревьях решений, и модель на основе наивного байесовского классификатора, для которой

задача была преобразована методом булеана меток. Все описанные модели имеют достаточно хорошую точность (см.рис. 4) и полноту (см.рис. 5), а также удовлетворительные значения метрики Хэмминга (см.рис. 3). Относительно метрики Хэмминга: чем она выше, тем модель считается хуже.

Модели, основанные на методе k ближайших соседей, обладают удовлетворительной точностью (см.рис. 4), полнотой (см.рис. 5) и удовлетворительными значениями метрики Хэмминга (см.рис. 3), однако их правильность лишь немного выше 0.7 (см.рис. 2).

Самую низкую правильность имеют модели наивного байесовского классификатора с преобразованиями многометочной задачи методами бинарной релевантности и цепочек классификаторов (см.рис. 2). Также они обладают максимальными значениями метрики Хэмминга среди всех моделей (см.рис. 3). Таким образом, несмотря на хорошую точность (см.рис. 4) и полноту (см.рис. 5), данные модели наивного байесовского классификатора не подходят для решения задачи определения изотопного состава.

7. Выводы

Решена задача многометочной классификации, а именно определен изотопный состав радиоактивных источников по спектрам гамма-излучения. Спектры были рассчитаны с помощью программы, разработанной на базе пакета библиотек Geant4.

Задача многометочной классификации была преобразована в набор задач однометочной классификации с помощью методов бинарной релевантности, булеана меток и цепочек классификаторов.

Для решения задач классификации были использованы такие методы, как метод k ближайших соседей, наивный байесовский классификатор, метод опорных векторов и деревья решений. Для оценки качества классификационных моделей были рассчитаны правильность, метрика Хэмминга, точность и полнота.

Наиболее подходящими для решения поставленной в работе задаче были определены методы опорных векторов и деревья решений. Хорошо зарекомендовал себя наивный байесовский классификатор, примененный к задачам, преобразованным с помощью булеана меток. Представленные результаты позволяют говорить о возможности использования данных методов для идентификации нуклидов по гамма-спектрам.

Литература:

1. *Routti J.T. and Prussin S.G.* Photopeak Method for the Computer Analysis of Gamma-Ray Spectra from Semiconductor Detectors // Nuclear Instruments and Methods. 1969. Vol. 72, Iss. 2. P. 125-142.
2. *Brutscher J., Arlt R., Czock K.H.* Isotope Identification Software for Gamma Spectra Taken with CdZnTe Detectors // Nuclear Instruments and Methods in Physics Research A. 2001. Vol. 458. P. 189-195.
3. *Yoshida E., Shizuma K., Endo S., Oka T.* Application of Neural Networks for the Analysis of Gamma-Ray Spectra Measured with a Ge Spectrometer // Nuclear Instruments and Methods in Physics Research A. 2002. Vol. 484. P. 557-563.
4. *Chen L. and Wei Y.-X.* Nuclide Identification Algorithm Based on K-L Transform and Neural Networks // Nuclear Instruments and Methods in Physics Research A. 2009. Vol. 598. P. 450-453.
5. *Alazaidah R. and Ahmad F.K.* Trending Challenges in Multi Label Classification // International Journal of Advanced Computer Science and Applications. 2016. Vol. 7, No. 10. P. 127-131.
6. *Herrera F., Charte F., Rivera A.J., del Jesus M.J.* Multilabel Classification. Problem Analysis, Metrics and Techniques. Springer International Publishing Switzerland, 2016, 194 p.
7. *Tsoumakas G. and Katakis I.* Multi-Label Classification: An Overview // International Journal of Data Warehousing and Mining. 2007. Vol. 3, No. 3. P. 1-13.
8. *Skrypnyk A.I.* Artificial Neural Networks in Gamma-Spectrum Based Radionuclide Identification // Telecommunications and Radio Engineering. 2016. Vol. 75, Iss. 12. P. 1121-1128.
9. *Sorower M.S.* A Literature Survey on Algorithms for Multi-Label Learning // Technical Report. Oregon State University, Corvallis, OR, USA. 2010.
10. *Read J., Pfahringer B., Holmes G., Frank E.* Classifier Chains for Multi-Label Classification // Machine Learning. 2011. Vol. 85. P. 333-359.
11. *Gibaja E. and Ventura S.* A Tutorial on Multilabel Learning // ACM Computing Surveys. 2015. Vol. 47, No. 3. Article 52, P. 1-38.
12. *Tsoumakas G., Katakis I., Vlahavas I.* Data Mining and Knowledge Discovery Handbook. Springer, Chapter Mining Multi-label Data, 2010. P. 667-685.
13. *Zhang M.-L. and Zhou Z.-H.* A Review on Multi-Label Learning Algorithms // IEEE Transactions on Knowledge and Data Engineering. 2014. Vol. 26, Iss. 8. P. 1819-1837.
14. *Agostinelli S. et al.* Geant4—a Simulation Toolkit // Nuclear Instruments and Methods in Physics Research A. 2003. Vol. 506, Iss. 3. P. 250-303.
15. *Allison J. et al.* Geant4 Developments and Applications // IEEE Transactions on Nuclear Science 2006. Vol. 53, Iss. 1. P. 270-278.
16. *Skrypnyk A.I. and Khazhmuradov M. A.* Monte-Carlo Simulation of Response of Semiconductor Detectors for Radionuclide Identification Devices // Problems of Atomic Science and Technology. 2015. No. 3(97). Series: Nuclear Physics Investigations (64). P. 89-94.
17. *Pedregosa F. et al.* Scikit-learn: Machine Learning in Python // Journal of Machine Learning Research. 2011. Vol. 12. P. 2825-2830.
18. *Szymanski P. and Kajdanowicz T.* Scikit-multilearn: A Scikit-Based Python Environment for Performing Multi-Label Classification // ArXiv e-prints. 2017.

Поступила в редколлегию 12.03.2018

Рецензент: д-р техн. наук, проф. Семенец В.В.

Скрышник Анна Ивановна, мл. научный сотрудник Института физики высоких энергий и ядерной физики (ИФВЭЯФ) Национального научного центра «Харьковский физико-технический институт» (ННЦ ХФТИ), аспирантка ННЦ ХФТИ. Научные интересы: взаимодействие гамма-излучения с веществом, математическое моделирование, машинное обучение. Адрес: Украина, 61108, Харьков, ул. Академическая, 1, тел.: +38(057)335-65-94, e-mail: belkas@kipt.kharkov.ua.

Федорченко Дмитрий Владимирович, канд. физ.-мат. наук, доцент, ст. научный сотрудник Института физики высоких энергий и ядерной физики (ИФВЭЯФ) Национального научного центра «Харьковский физико-технический институт» (ННЦ ХФТИ). Научные интересы: методы Монте-Карло, математическое моделирование. Адрес: Украина, 61108, Харьков, ул. Академическая, 1, тел.: +38 (057) 335-65-94, e-mail: fdima@kipt.kharkov.ua.

Хажмуратов Манап Ахмадович, д-р техн. наук, профессор, вр.и.о. директора Института физики высоких энергий и ядерной физики (ИФВЭЯФ) Национального научного центра «Харьковский физико-технический институт» (ННЦ ХФТИ). Научные интересы: методы Монте-Карло, математическое моделирование, автоматизированные системы управления. Адрес: Украина, 61108, Харьков, ул. Академическая, 1, тел.: +38(057)335-68-46, e-mail: kha-zhm@kipt.kharkov.ua.

Skrypnyk Anna Ivanovna, researcher at the Institute of High-Energy Physics and Nuclear Physics (IFIEAF) of the National Science Center "Kharkiv Physical-Technical Institute" (NSC KhPTI), PhD student of the National Academy of Sciences of the KPI. Scientific interests: interaction of gamma radiation with matter, mathematical modeling, machine learning. Address: Ukraine, 61108, Kharkov, st. Akademicheskaya, 1, tel: +38 (057) 335-65-94, e-mail: belkas@kipt.kharkov.ua.

Fedorchenko Dmitry Vladimirovich, PhD, associate professor, senior researcher at the Institute of High-Energy Physics and Nuclear Physics (IRVIEF) of the National Science Center "Kharkiv Physico-Technical Institute" (NSC KhPTI). Scientific interests: Monte Carlo methods, mathematical modeling. Address: Ukraine, 61108, Kharkov, st. Akademicheskaya, 1, tel: +38 (057) 335-65-94, e-mail: fdima@kipt.kharkov.ua.

Khazhmuradov Manap Akhmadovich, Dr.Sc., professor, acting director of Institute of High-Energy Physics and Nuclear Physics (IFIEAF) of the National Science Center "Kharkiv Physical-Technical Institute" (NSC KhPTI). Scientific interests: Monte Carlo methods, mathematical modeling, automated control systems. Address: Ukraine, 61108, Kharkov, st. Akademicheskaya, 1, tel.: +38 (057) 335-68-46, e-mail: kha-zhm@kipt.kharkov.ua.