

## Исследование возможности использования искусственной нейронной сети для распознавания и оценки вклада отдельных радионуклидов в суммарный бета-спектр

В.С. Репин

Санкт-Петербургский научно-исследовательский институт радиационной гигиены имени профессора П.В. Рамзаева, Федеральная служба по надзору в сфере защиты прав потребителей и благополучия человека, Санкт-Петербург, Россия

*Целью работы является исследование возможности применения искусственной нейронной сети для идентификации и количественной оценки содержания отдельных радионуклидов в суммарном бета-спектре. Нейронная сеть реализована средствами Matlab R2020b. Для исследования использована однослойная нейронная сеть прямого распространения с одним невидимым слоем из 10 нейронов и 3 выходами (по числу радионуклидов). Для тестирования и изучения возможностей искусственной нейронной сети были выбраны 3 гладких модельных спектра —  $^{40}\text{K}$ ,  $^{137}\text{Cs}$  и  $^{90}\text{Sr}$ , полученные на жидкостном спектрометре Quantulus 1220. Результаты исследования показали, что нейронные сети являются эффективным методом распознавания вклада отдельного радионуклида или установления его наличия в суммарном бета-спектре. Точность оценки вклада зависит от гладкости спектра и не превышает 30%, для вкладов более 10%, что вполне пригодно для практического использования. Для «зашумленных» спектров метод может использоваться для предварительной оценки вкладов отдельных радионуклидов в суммарный спектр, окончательное значение которых может быть рассчитано методами минимизации при подгонке формы измеренного и распознаваемого спектра.*

**Ключевые слова:** нейронные сети, жидкостная бета-спектрометрия, декомпозиция спектра, обучающая выборка, достоверность.

### Введение

Задача определения радионуклидного состава исследуемого образца в спектрометрии, включая бета-спектрометрию и бета-радиометрию, является традиционной, широко распространенной и практически реализованной.

Существует большое количество компьютерных программ («SpectralLine» – разработки ООО «ЛСПМ» [1], «ASW» – разработки НТЦ «РАДЭК» [2], «СПЕКТР» – [3], «Прогресс» – разработки ООО «НТЦ Амплитуда» [4], SpectraDec [5] и др.), предназначенных для расшифровки бета-спектров, полученных на твердотельных и жидкостных детекторах, как с известным, так и с неизвестным радионуклидным составом. Бета-спектрометрия в ряде случаев позволяет избежать сложных и трудоемких радиохимических исследований.

Традиционные алгоритмы расшифровки бета-спектров, нашедшие наибольшее распространение в последние годы, основаны на использовании метода наименьших квадратов (МНК). Для реализации данного метода необходимо располагать библиотекой эталонных радионуклидов, которые предположительно находятся в счетном образце. Суть метода состоит в построении из эталонных спектров суммарного модельного спектра,

максимально близкого по форме к измеренному спектру. Это достигается путем подбора оптимального набора весовых коэффициентов с использованием компьютерных алгоритмов минимизации [6–11]. Несмотря на достоинства МНК, успех его реализации зависит от соотношения полезных и фоновых составляющих спектра и идентичности набора радионуклидов в модельном и измеренном спектрах. МНК по своей природе формален, и вне зависимости от формы измеренного спектра всегда найдется решение, которое с формальной точки зрения будет оптимальным [11], что нередко происходит при неверно выбранных начальных условиях.

В последнее время все более пристальное внимание специалистов приковано к практическому применению искусственных нейронных сетей. Искусственная нейронная сеть (ИНС) – это математическая модель и её программное обеспечение, построенные по принципу организации и функционирования биологических нейронных сетей, наподобие клеток головного мозга [11–25]. Важнейшим свойством нейронных сетей, по сравнению с программами, работающими на основе алгоритмов, является возможность обучения. Суть обучения заключается в поиске оптимальных коэффициентов связи между нейронами. В процессе обучения нейронная сеть спо-

Репин Виктор Степанович

Санкт-Петербургский научно-исследовательский институт радиационной гигиены имени профессора П.В. Рамзаева.

Адрес для переписки: 197101, Санкт-Петербург, ул. Мира, д. 8; E-mail: v.repin@mail.ru

собна узнавать объекты, речь, выявлять сложные зависимости между входными и выходными данными. В случае успешного обучения сеть может дать правильный ответ даже в случае нечетких входных данных [20].

В научной литературе имеется ограниченное число работ по использованию ИНС для распознавания бета-спектров радионуклидов. В публикациях [26–28] приведены примеры использования ИНС для мониторинга спектра пучка электронов промышленного ускорителя электронов. В работе [28] предложено использовать ИНС для создания объединённой базы жидко-сцинтилляционных спектров, позволяющей учесть индивидуальные особенности приборов и создать библиотеку калибровочных спектров для конкретного прибора или его модификации.

Особенностью бета-спектров является их непрерывность в диапазоне энергий от нуля до максимальной, граничной энергии. Признаками для распознавания отдельных радионуклидов, полученных методом жидкостной спектрометрии, могут быть: верхняя граница бета-спектра, форма бета-спектра, пики конверсионных электронов, изгибы, связанные с присутствием в спектре материнских и дочерних радионуклидов, которые совместно определяют уникальную форму суммарного спектра.

**Цель исследования** – оценить возможности практического применения ИНС для выявления и количественной оценки вкладов отдельных радионуклидов в суммарном бета-спектре.

### Материалы и методы

Методический раздел данного исследования включал:

- выбор ИНС и среды моделирования;
- подготовку обучающей выборки и обучение ИНС;
- тестирование ИНС.


#### Выбор архитектуры ИНС и среды моделирования

Сформулированный выше тип задачи относится к задачам идентификации, то есть к выделению в рассматриваемом массиве данных характерных признаков, позволяющих связать их с конкретными цифровыми образами (в нашем случае с бета-спектрами радионуклидов).

К решению данного типа задач лучше всего применимы нейронные сети прямого распространения (НСПР) [21–23], общий вид которых показан на рисунке 1.

Нейронные сети прямого распространения передают информацию от входа к выходу. Входными данными в нашем случае является количество импульсов в каналах анализатора, а выходными – весовые коэффициенты вклада идентифицированных спектров радионуклидов в суммарный спектр. НСПР обычно обучается по методу обратного распространения ошибки. Ошибка является разницей между входом и выходом. Если у сети есть достаточное количество скрытых нейронов, она теоретически способна смоделировать взаимодействие между входными и выходными данными.

Современные вычислительные средства облегчают задачу построения нейросети, поскольку имеют встроенные блоки, позволяющие сформировать нужную конфигурацию нейросети. В данной работе для построения ИНС, ее обучения и последующего изучения свойств был выбран MATLAB R2020b.



**Рис. 1.** Общий вид нейронной сети прямого распространения с одним скрытым слоем

[Fig. 1. General view of a feedforward neural network with one hidden layer]

Среда MATLAB включает широкий набор инструментов, одним из которых является Neural Network Toolbox (NNT), который содержит средства для разработки и визуализации нейронных сетей. NNT обеспечивает поддержку типовых задач. Средства анализа и моделирования MATLAB позволяют быстро оценивать качество окончательного результата распознавания [28–34].


Для создания ИНС и ее тестирования в программной среде MATLAB была выбрана однослойная нейронная сеть прямого распространения feed forward neural net (FFNN) с одним невидимым слоем. Настройка сети состояла в определении количества входов и выходов, а также количества нейронов в скрытом слое. Для тестирования была построена конфигурация сети, состоящая из 1024 входных сигналов (по числу каналов в бета-спектре) и 3 выходов – количество радионуклидов, представленных в тестируемой выборке.

Оптимальное количество нейронов скрытого слоя –  $M$  первоначально определялось по правилу геометрической пирамиды, предложенной в работе [25]:  $M = \sqrt{1024 \cdot 3} \approx 55$ , однако оперативная память компьютера не позволила произвести обучение ИНС для 55 нейронов, поэтому обучение и тестирование было произведено для 10 нейронов скрытого слоя.

#### Подготовка обучающей выборки и обучение ИНС

Для тестирования и изучения возможностей ИНС из числа имеющихся спектров были отобраны 3 наиболее гладких бета-спектра  $^{40}\text{K}$ ,  $^{137}\text{Cs}$  и  $^{90}\text{Sr}$ , полученные ранее на жидкостном спектрометре Quantulus-1220. Форма этих спектров показана на рисунке 1. Особенностью регистрации и вывода спектров на Quantulus-1220 является логарифмическая шкала преобразования амплитуды сигнала в номер канала регистрации. Такой способ регистрации, как это видно из рисунка 2, позволяет растянуть начальную область спектра.

Обучающая выборка состояла из двух массивов данных: массива, включающего 10 тысяч спектров, содер-



**Рис. 2.** Форма модельных спектров  $^{40}\text{K}$ ,  $^{137}\text{Cs}$  и  $^{90}\text{Sr}$ , используемых для обучения искусственной нейронной сети (ИНС)

[Fig. 2.  $^{40}\text{K}$ ,  $^{137}\text{Cs}$  and  $^{90}\text{Sr}$  reference spectra used for artificial neural network (ANN) training]

[Legend (top down): Spectrum of  $^{40}\text{K}$ ; Spectrum of  $^{137}\text{Cs}$ ; Spectrum of  $^{90}\text{Sr}$ ]

жащих радионуклиды, весовые коэффициенты которых в диапазоне от 0 до 1 устанавливались случайным образом, и массива, который содержал наборы весовых коэффициентов для соответствующих спектров первого массива. Данный объем выборки обеспечил высокую плотность заполнения диапазона весовых коэффициентов и последующую корректную оценку точности работы ИНС.

Суть обучения заключалась в том, чтобы предъявить на вход ИНС спектр, состоящий из смеси перечисленных выше радионуклидов, и сообщить ИНС вклад каждого радионуклида в данный спектр.

По окончании обучения ИНС была готова для тестирования и использования, а результатом ее работы становилось выявление и оценка вкладов радионуклидов в произвольном спектре смеси перечисленных радионуклидов.


На рисунке 3 показан пример работы ИНС при распознавании вкладов  $^{40}\text{K}$ ,  $^{137}\text{Cs}$  и  $^{90}\text{Sr}$  с соотношением 0,2:0,5:0,3. Полученный в результате идентификации радионуклидов суммарный спектр показан на рисунке 3 сплошной линией. Из данного примера видно вполне удовлетворительное совпадение идентифицированных и тестируемых спектров радионуклидов и их сумм.

#### Тестирование свойств ИНС после обучения

В зависимости от активности радионуклидов в счетных образцах, времени набора спектров формы спектров различаются степенью гладкости.

Целью тестирования ИНС является оценка точности распознавания в суммарном спектре вкладов отдельных радионуклидов при их случайном соотношении.


Исследование было выполнено как для гладких, так и для «зашумленных» спектров, то есть спектров, в которых число импульсов в каждом канале изменялось случайным образом. Пример «зашумленных» спектров показан на рисунке 4.



**Рис. 3.** Пример распознавания искусственной нейросетью вкладов отдельных радионуклидов в тестируемый сглаженный спектр

[Fig. 3. An example of recognition by an artificial neural network (ANN) of the contributions of individual radionuclides to the tested smoothed spectrum]

[Legend (top down): Tested spectrum after smoothing; Actual spectrum of  $^{40}\text{K}$ ; Recognized spectrum of  $^{40}\text{K}$ ; Actual spectrum of  $^{137}\text{Cs}$ ; Recognized spectrum of  $^{137}\text{Cs}$ ; Actual spectrum of  $^{90}\text{Sr}$ ; Recognized spectrum of  $^{90}\text{Sr}$ ; Spectrum, based on ANN recognition]



**Рис. 4.** Пример статистического «зашумления» спектров

[Fig. 4. An example of statistical «noising» of spectra  
Legend (top down): Summary spectrum; Strontium-90 spectrum; Caesium-137 spectrum; potassium-40 spectrum]

Тестирование проведено для 3 вариантов композиции суммарных тестируемых спектров:

- композиция гладких спектров;
- композиция спектров с «зашумлением» числа импульсов в каналах анализатора;
- композиция спектров с «зашумлением» и последующим сглаживанием суммарного спектра.

Для каждого варианта тестирования ИНС создавался массив суммарных спектров, формируемых в соответствии со следующим соотношением:

$$\text{Sum\_sp} = k_K \cdot \text{sp}_K + k_{Cs} \cdot \text{sp}_{Cs} + k_{Sr} \cdot \text{sp}_{Sr}, \quad (1)$$

где

$k_K$ ,  $k_{Cs}$ ,  $k_{Sr}$  – коэффициенты вкладов радионуклидов  $^{40}\text{K}$ ,  $^{137}\text{Cs}$  и  $^{90}\text{Sr}$  в суммарный спектр Sum\_sp;

$sp_K, sp_{Cs}, sp_{Sr}$  – эталонные гладкие спектры  $^{40}K$ ,  $^{137}Cs$  и  $^{90}Sr$ .

Коэффициенты  $k_K, k_{Cs}, k_{Sr}$  были получены с помощью генератора случайных чисел в диапазоне от 0 до 1.

Результатом тестирования ИНС стал массив распознанных вкладов размером  $10\,000 \times 3$ .

Точность распознавания оценивалась посредством расчета абсолютной величины относительной ошибки разницы между тестируемым и распознанным вкладом по формуле:

$$Error_{rn} = \frac{Abs(K_{rn}^{Recogn} - K_{rn})}{K_{rn}} * 100\%, \quad (2)$$

где

$Error_{rn}$  – абсолютная величина относительной ошибки разницы между тестируемым  $K_{rn}$  и распознанным  $K_{rn}^{Recogn}$  вкладом радионуклида « $rn$ »

Моделирование случайного числа импульсов в  $i$ -м канале анализатора –  $N_{rand(i)}$  для варианта тестирования 2 осуществлялось по формуле:

$$N_{rand(i)} = K_{rn} \cdot N_{sp(i)} + rnd(i) \cdot \sqrt{K_{rn} \cdot N_{sp(i)}}, \quad (3)$$

где

$K_{rn}$  – тестируемый коэффициент вклада спектра « $rn$ » в суммарный спектр;

$N_{sp(i)}$  – число импульсов в  $i$ -м канале спектра;

$rnd(i)$  – значения, равные -1 или +1, если  $rnd(i)$  меньше 0,5 или больше 0,5 соответственно, и равные 0 при значении  $rnd(i) = 0$ .

Для третьего варианта тестирования спектры, полученные по варианту 2, подвергались процедуре сглаживания методом скользящей средней.

Надежность метода распознавания вкладов с использованием ИНС оценивалась по величине ошибки разницы между распознанным вкладом отдельного радионуклида и значением, заданным при тестировании. Были выделены следующие диапазоны ошибок:

- менее 10%;
- от 10 до 30%;
- от 30 до 100%;

– более 100%.

Результаты тестирования для всех трех вариантов формирования тестируемых спектров представлены в таблице.

Из таблицы видно, что наибольшая точность распознавания вкладов радионуклидов реализуется для варианта 1 – гладких спектров, для которых доля спектров, вклады которых определены с ошибками менее 10% (высокая точность), лежит в интервале от 90 до 99%. Доля спектров с ошибками менее 30% (приемлемая точность) не превышает 7,3%, а доля спектров с ошибками распознавания вкладов более 100% (ориентировочные значения вкладов) составляет доли процента.

Точность распознавания вкладов спектров, сформированных по варианту 2, невелика. В приемлемый диапазон точности до 30% попадает 72% спектров  $^{40}K$ , 32%  $^{137}Cs$  и 39%  $^{90}Sr$ .

Сглаживание спектров (вариант 3) повышает точность распознавания в 1,2–2,3 раза по сравнению с вариантом 2: 88% для  $^{40}K$ , 75% для  $^{137}Cs$  и 70% для  $^{90}Sr$ , поэтому такой способ предварительной подготовки спектра является весьма эффективным. Доля спектров с приемлемой и ориентировочной точностью распознавания вкладов при третьем варианте обработки спектров достигает 90%.

#### Исследование точности и линейности распознавания вклада радионуклида в суммарный спектр в зависимости от величины вклада

Приведенные в таблице результаты дают общее представление о процентах, распознанных с приемлемой и ориентировочной точностью вкладов, но не дают ответа на вопрос, как ошибка распознавания связана с величиной вклада и является ли связь между тестируемым и распознанным вкладом линейной. Пример результата такого исследования для зашумленных спектров  $^{137}Cs$  представлен на рисунке 5. Из рисунка 5 видно, что связь между распознанными и тестируемыми значениями вкладов описывается уравнением линейной регрессии  $y = 1,003 \cdot x - 0,03$ . Коэффициент корреляции равен 0,97.

Таблица

Распределение процентной доли распознанных вкладов радионуклидов в зависимости от ошибки распознавания, %


[Table

Distribution of the percentage of recognized contributions of radionuclides depending on the recognition error, %]

Радионуклид [Radionuclide]	Диапазон ошибок, [Error range] %	Вариант тестируемого спектра [Spectrum Test Variant]		
		Вариант 1. Смесь эталонных спектров (гладкий спектр), % [Variant 1. A mixture of reference spectra (smooth spec- trum), %]	Вариант 2. Смесь эталонных спектров с моделированием случайного числа импульсов в каналах анализатора, % [Variant 2. A mixture of reference spectra with modeling a random num- ber of pulses in the analyzer channels, %]	Вариант 3. Смесь эталонных спектров со сглаживанием случайного числа импульсов в каналах анализатора, % [Variant 3. A mixture of reference spectra with smoothing a random number of pulses in the analyzer channels, %]
$^{40}K$ , %	<10	99,48	25,98	<b>69,80</b>
	10–30	0,40	35,75	<b>18,08</b>
	30–100	0,08	27,10	8,42
	>100	0,04	11,17	3,70



Радионуклид [Radionuclide]	Диапазон ошибок, [Error range] %	Вариант тестируемого спектра [Spectrum Test Variant]		
		Вариант 1. Смесь эталонных спектров (гладкий спектр), % [Variant 1. A mixture of reference spectra (smooth spec- trum), %]	Вариант 2. Смесь эталонных спектров с моделированием случайного числа импульсов в каналах анализатора, % [Variant 2. A mixture of reference spectra with modeling a random num- ber of pulses in the analyzer channels, %]	Вариант 3. Смесь эталонных спектров со сглаживанием случайного числа импульсов в каналах анализатора, % [Variant 3. A mixture of reference spectra with smoothing a random number of pulses in the analyzer channels, %]
<sup>137</sup> Cs	<10	89,43	11,10	<b>39,45</b>
	10–30	7,26	20,92	<b>35,99</b>
	30–100	2,41	39,54	18,75
	>100	0,90	28,44	5,81
<sup>90</sup> Sr	<10	97,59	15,69	<b>36,95</b>
	10–30	1,70	23,53	<b>32,58</b>
	30–100	0,46	34,66	22,37
	>100	0,25	26,13	8,10




**Рис. 5.** Соотношение между тестируемым и распознаваемым вкладом <sup>137</sup>Cs в суммарный спектр  
[Fig. 5. The relationship between the tested and recognized contribution of <sup>137</sup>Cs to the summary spectrum]

Аналогичные уравнения регрессии, описывающие тесную линейную связь между распознанными и тестируемыми значениями вкладов, получены для <sup>40</sup>K и <sup>90</sup>Sr.

Исследование зависимости ошибки распознавания от величины вклада показало (рис. 6), что для сглаженных спектров с моделированием случайного числа импульсов в каналах анализатора для вкладов в диапазоне от 0,1 до 0,3 ошибка может достигать 30–100% и превышает 100%, если вклад менее 0,1. Для гладких модельных спектров, из которых был составлен суммарный спектр, ошибки распознавания существенно меньше и превышают 30% только при вкладах менее 0,02.

Результаты выполненного исследования показали, что нейронные сети являются вполне эффективным методом распознавания отдельных радионуклидов в суммарном бета-спектре. Более высокая точность распознавания



**Рис. 6.** Зависимость ошибки распознавания вкладов радионуклидов в суммарный спектр в зависимости от их величины (верхние кривые – с моделированием случайного числа импульсов; нижние кривые – гладкие эталонные спектры)  
[Fig. 6. The error of recognition of the radionuclides contributions to the summary spectrum depending on the value of contribution (upper curves – with modeling of a random number of pulses; lower curves – smooth etalon spectra)]

с ошибкой менее 30% достигается при использовании гладких или сглаженных спектров. Учитывая, что для практических целей точность оценки вклада отдельного радионуклида 30% является приемлемой, метод ИНС позволяет уверенно идентифицировать весовой вклад в суммарный спектр отдельного радионуклида, начиная с относительного вклада 10%.

Для негладко очерченных, «зашумленных» спектров метод ИНС может быть рекомендован для предварительной оценки вкладов радионуклидов с последующим уточнением этих вкладов итерационными методами минимизации методом наименьших квадратов.

## Выводы

Результаты исследования возможностей искусственной нейронной сети в распознавании вкладов отдельных радионуклидов в суммарном бета-спектре показали:

1. Точность распознавания вклада радионуклида в суммарный бета-спектр с помощью искусственной нейронной сети зависит от гладкости спектра и относительного вклада радионуклида в суммарный спектр. Для гладких спектров вклады на уровне 0,02 уверенно идентифицируются с ошибкой до 30%, а для статистически зашумленных спектров – на уровне 0,2 с ошибкой до 100%.

2. Точность распознавания вклада радионуклидов при сглаживании спектров позволяет снизить ошибку распознавания в 1,2–2,3 раза, что позволяет расширить возможности ИНС для распознавания.

3. Искусственные нейронные сети могут успешно использоваться для расшифровки бета-спектров.

4. Наряду с идентификацией радионуклидов и оценкой их вклада, искусственная нейронная сеть может использоваться для предварительной оценки вкладов радионуклидов в статистически «зашумленных» спектрах в качестве начальных условий с последующим уточнением этих вкладов методом наименьших квадратов в процессе окончательной подгонки теоретического и измеренного спектра.

## Литература

- Официальный сайт лаборатории спектрометрии и радиометрии (ЛСРМ). URL: [http://www.lsrn.ru/products/detail.php?ELEMENT\\_CODE=spectraline\\_1.6/](http://www.lsrn.ru/products/detail.php?ELEMENT_CODE=spectraline_1.6/) (Дата обращения 20.10.2020).
- Официальный сайт ООО «Научно-Технический Центр «РАДЕК». URL: <https://www.radek.ru/product/Programmnoe-obespechenie/95/> (Дата обращения 20.10.2020).
- Официальный сайт ООО «Спектр». URL: <http://spectrad.ru/> (Дата обращения 20.10.2020).
- Официальный сайт ООО «НТЦ Амплитуда». URL: <http://amplituda.ru/catalog/radiatsionnyy-kontrol/programmnoe-obespechenie/> (Дата обращения 20.10.2020).
- Официальный сайт компании «TALS OY». URL: <https://www.tals.eu/spectradec> (Дата обращения 20.10.2020).
- Ермаков А. И., Каширин И. А., Малиновский С. В., Соболев А. И., Тихомиров В. А. Жидкосцинтилляционная  $\beta$ – $\alpha$ -спектрометрия // Атомная энергия. 2002. Том 92, вып. 1. С. 68–75.
- Kashirin I.A., Ermakov A.I., Malinovsky S.V., et al. Liquid scintillation determination of low level components in complex mixtures of radionuclides // Appl. Rad. Isot. 2000. Vol. 53. P. 303–308.
- Belanov S.V., Kashirin I.A., Malinovsky S.V., et al. Method for identifying radionuclides in probes using a liquid scintillation sensor. PCT № 94/30185.
- Беланов С.В., Каширин И.А., Малиновский С.В., и др. Способ идентификации радионуклидов с помощью жидкосцинтилляционного счетчика. Пат. № 2120646 (приоритет от 08.12.97).
- Методика измерения активности радионуклидов с использованием сцинтилляционного гамма-спектрометра с программным обеспечением «Прогресс». Москва, 2016.
- Ососков Г.А., Полянский А., Пузынин И.В. Современные методы обработки экспериментальных данных в физике высоких энергий // Физика элементарных частиц и атомного ядра. 2002. Т. 33, вып. 3. С. 676–745.
- Вакуленко С.А., Жихарева А.А. Практический курс по нейронным сетям. СПб.: Университет ИТМО, 2018. 71 с.
- Галушкин А.И. Теория нейронных сетей. М.: ИПРЖР, 2000. 241 с.
- Галушкин А.И., Цыпкин Я.З. Нейронные сети: история развития. М.: ИПРЖР, 2002. 735 с.
- Гаскаров Д.В. Интеллектуальные информационные системы. Учебное пособие для вузов. М.: Высшая школа, 2003. 413 с.
- Головкин В.А. Нейронные сети: обучение, организация и применение. М.: ИПРЖР, 2001. 256 с.
- Девятков В.В. Системы искусственного интеллекта. М.: Издательство МГТУ им. Баумана, 2001. 352 с.
- Джексон П. Экспертные системы. М.: Издательский дом «Вильямс», 2001. 624 с.
- Комарцова Л.Г., Максимов А.В. Нейрокомпьютеры. М.: МГТУ Баумана, 2004. 400 с.
- Кисель И.В., Нескоромный В.Н., Ососков Г.А. Применение нейронных сетей в экспериментальной физике // ЭЧАЯ. 1993. Т. 24, вып. 6. С. 1551–1595.
- Ососков Г.А. Пальчик В.В., Потребенников Ю.К., и др. Использование нейронных сетей для улучшения интерпретации эксперимента EXCHARM // Матем. моделир. 1999. Т. 11, вып. 10. С. 116–126.
- Комашинский В.И., Смирнов Д.А. Нейронные сети и их применение в системах управления и связи. М.: Горячая линия Телеком, 2002. 94 с.
- Кириченко А.А. Нейропакеты – современный интеллектуальный инструмент исследователя // Сетевое электронное издание учебного пособия, 2013. 297 с.
- Брилюк Д.В., Старовойтов В.В. Распознавание человека по изображению лица нейросетевыми методами. Препринт. Ин-т техн. Кибернетики НАН Беларуси; No 2. Минск, 2002. 54 с.
- Masters T. Practical Neural Network Recipes in C++. Morgan Kaufmann, 1993. 493 p.
- Baiev O., Lazurik V. Advantages of neural networks for deriving an electrons spectrum from depth-charge curve. «IEEE Nuclear Science Symposium and Medical Imaging Conference», Conference Publications, Valencia, Spain. 2011. P. 1395–1397.
- Baiev O., Lazurik V., Didenko I. Use of Neural Networks for Monitoring Beam Spectrum of Industrial Electron Accelerators. International Conference on Information and Communication Technologies in Education, Research, and Industrial Applications (ICTERI), 2013.
- Малиновский С.В., Каширин И.А., Тихомиров В.А. Создание объединенной библиотеки спектров жс tricarb. Сборник материалов XVI ежегодного семинара «Спектрометрический анализ. Аппаратура и обработка данных на ПЭВМ», Обнинск, ГЦИПК, 2010. С. 23–35.
- Николаева С.Г. Нейронные сети. Реализация в Matlab: учебное пособие. Казань: Казан. гос. энерг. ун-т, 2015. 92 с.
- Дьяконов В.В. Matlab 6: Учебный курс. СПб.: Питер, 2002. 672 с.
- Бураков М.В. Нейронные сети и нейроконтроллеры: учеб. пособие. СПб.: ГУАП, 2013. 284 с.
- Ковалев С.М., Хатламаджиян А.Е. Моделирование искусственных нейронных сетей в среде MATLAB: Учебно-методическое пособие к лабораторным работам. Рост. гос. ун-т путей сообщения. Ростов н/Д, 2008. 35 с.
- Медведев В.С., Потемкин В.Г. Нейронные сети. MATLAB 6. М.: Диалог-МИФИ, 2002. 496 с.
- Николаев С.В., Баженов Р.И. Распознавание образов с помощью нейронных сетей в среде MatlabR2009b. 2015. No. 13 (13-2015). URL: <http://nauka-rastudent.ru/13/2355/> (Дата обращения 20.10.2020).

Поступила: 26.10.2020 г.

**Репин Виктор Степанович** – доктор биологических наук, руководитель отдела здоровья Санкт-Петербургского научно-исследовательского института радиационной гигиены имени профессора П.В. Рамзаева Федеральной службы по надзору в сфере защиты прав потребителей и благополучия человека. **Адрес для переписки:** 197101, Россия, Санкт-Петербург, ул. Мира, д. 8; E-mail: v.repin@mail.ru

**Для цитирования:** Репин В.С. Исследование возможности использования искусственной нейронной сети для распознавания и оценки вклада отдельных радионуклидов в суммарный бета-спектр // Радиационная гигиена. 2020. Т. 13, № 4. С. 74–81. DOI: 10.21514/1998-426X-2020-13-4-74-81

## Study of the possibility of using an artificial neural network to recognize and assess the contribution of individual radionuclides to the total beta spectrum

Viktor S. Repin

Saint-Petersburg Research Institute of Radiation Hygiene after Professor P.V. Ramzaev, Federal Service for Surveillance on Consumer Rights Protection and Human Well-Being, Saint-Petersburg, Russia

*The aim of this work is to study the possibility of using an artificial neural network for identification and quantitative assessment of the content of individual radionuclides in the total beta spectrum. The neural network implemented by using of Matlab R2020b. A single-layer feedforward neural network with one invisible layer of 10 neurons and 3 outputs (according to the number of radionuclides) was used. To test and study the capabilities of the artificial neural network, 3 smooth model spectra were selected —  $^{40}\text{K}$ ,  $^{137}\text{Cs}$  and  $^{90}\text{Sr}$ , obtained on the liquid spectrometer Quantulus 1220. The results of the study showed that neural networks are an effective method for recognizing of the contribution of an individual radionuclide or establishing its presence in the total beta spectrum. The recognition accuracy depends on the smoothness of the spectrum and does not exceed 30% if the share of the radionuclide in the total spectrum is more than 10%, which is quite suitable for practical use. For statistically «noising» spectra, the method can be used to preliminary estimate the weight coefficients of individual radionuclides, the final value of which can be obtained by minimization methods with subsequent statistical criterial fitting of the total spectrum shape.*

**Key words:** neural networks, liquid beta spectrometry, spectrum decomposition, training sample, reliability.

### References

1. Official site of the laboratory of spectrometry and radiometry (LSRM). Available from: [http://www.lsrn.ru/products/detail.php?ELEMENT\\_CODE=spectraline\\_1.6/](http://www.lsrn.ru/products/detail.php?ELEMENT_CODE=spectraline_1.6/) [Accessed Nov 20, 2020] (In Russian)
2. Official site of Ltd STC [«RADEC»]. Available from: <https://www.radek.ru/product/Programmnoe-obespechenie/95/> [Accessed Nov 20, 2020] (In Russian)
3. Official site of Ltd «Spectr». Available from: <http://spectrad.ru/> [Accessed Nov 20, 2020] (In Russian)
4. Official site of Ltd [«STC Amplituda»]. Available from: <http://amplituda.ru/catalog/radiatsionnyy-kontrol/programmnoe-obespechenie/> [Accessed Nov 20, 2020] (In Russian)
5. Official site of the company «TALS OY». Available from: <https://www.tals.eu/spectradec> [Accessed Nov 20, 2020]
6. Ermakov AI, Kashirin IA, Malinovsky SV, Sobolev AI, Tikhomirov VA. Liquid  $\beta$ — $\alpha$ -spectrometry. *Atomnaya energiya = Atomic Energy*. 2002;92(1): 68–75 (In Russian)
7. Kashirin IA, Ermakov AI, Malinovsky SV, Belanov SV, Sapozhnikov YA, Efimov KM, et al. Liquid scintillation determination of low-level components in complex mixtures of radionuclides. *Applied Radiation and Isotopes*. 2000;53(1–2): 303–308.
8. Belanov SV, Kashirin IA, Malinovsky SV, et al. Method for identifying radionuclides in probes using a liquid scintillation sensor. PCT № 94/30185.
9. Belanov SB, Kashirin IA, Malinovsky SV, et al. Method for the identification of radionuclides using a liquid counter. Pat. № 2120646 (priority date 08.12.97) (In Russian)
10. Methods for measuring the activity of radionuclides using a scintillation gamma spectrometer with the «Progress» software. Moscow; 2016. (In Russian)
11. Ososkov GA, Polyansky A, Puzynin IV. Modern methods of processing experimental data in high energy physics. *Fizika elementarnykh chastits i atomnogo yadra = Physics of elementary particles and atomic nucleus*. 2002; 33(3): 676–745 (In Russian)
12. Vakulenko SA, Zhikhareva AA. Practical course on neural networks. Saint-Petersburg: ITMO University; 2018. 71 p. (In Russian)

**Viktor S. Repin**

Saint-Petersburg Research Institute of Radiation Hygiene after Professor P.V. Ramzaev.

**Address for correspondence:** Mira str., 8, Saint-Petersburg, 197101, Russia; E-mail: v.repin@mail.ru

13. Galushkin AI. Theory of neural networks. Moscow: IPRZhR; 2000. 241 p. (In Russian)
14. Galushkin AI, Tsyplin YaZ. Neural networks: history of development. Moscow: IPRZhR; 2002. 735 p. (In Russian)
15. Gaskarov DV. Intelligent information systems. Textbook for universities. Moscow: Vysshaya shkola; 2003. 413 p. (In Russian)
16. Golovko VA. Neural networks: training, organization and application. Moscow: IPRZhR; 2001. 256 p. (In Russian)
17. Devyatkov VV. Artificial intelligence systems. Moscow: Publishing house Bauman Moscow State Technical University; 2001. 352 p. (In Russian)
18. Dzheksan P. Expert systems. Moscow: Williams Publishing House; 2001. 624 p. (In Russian)
19. Komartsova L.G., Maksimov A.V. Neurocomputers. Moscow: Publishing house Bauman Moscow State Technical University; 2004. 400 p. (In Russian)
20. Kisel IV, Neskromnyy VN, Ososkov GA. Application of neural networks in experimental physics. *EChAYA = ECHAYA*. 1993;24(6): 1551-1595 (In Russian)
21. Ososkov GA, Palchik VV, Potrebennikov YuK, Tatishvili GT, Shepelev VB. Using neural networks to improve the interpretation of the EXCHARM experiment. *Matematicheskoe modelirovanie = Mathematical modeling*. 1999;11(10): 116-126 (In Russian)
22. Komashinsky VI, Smirnov DA. Neural networks and their application in control and communication systems. Moscow: Telecom hotline; 2002. 94 p. (In Russian)
23. Kirichenko AA. Neuropackages are a modern intellectual tool of the researcher. Online electronic publication of the textbook; 2013. 297 p. (In Russian)
24. Brilyuk DV, Starovoytov VV. Human recognition by facial image using neural network methods. Minsk; 2002. 54 p. (Preprint/Cybernetics University of NAS of Belarus; No 2) (In Russian)
25. Masters T. Practical Neural Network Recipes in C++. Morgan Kaufmann; 1993. 493 p.
26. Baiev O, Lazurik V. Advantages of neural networks for deriving an electrons spectrum from depth-charge curve. «IEEE Nuclear Science Symposium and Medical Imaging Conference», Conference Publications, Valencia, Spain; 2011. P. 1395-1397.
27. Baiev O, Lazurik V, Didenko I. Use of Neural Networks for Monitoring Beam Spectrum of Industrial Electron Accelerators. International Conference on Information and Communication Technologies in Education, Research, and Industrial Applications (ICTERI), 2013.
28. Malinovsky SV, Kashirin IA, Tikhomirov VA. Creation of a unified library of LSS spectra TRICARB. Collection of materials of the XVI annual seminar «Spectrometric analysis. Hardware and data processing on a PC», Obninsk, GCIPIK; 2010. P. 23-35. (In Russian).
29. Nikolaev SG. Neural networks. Implementation in Matlab: a Tutorial. Kazan: Kazan. State Energ. Univer.; 2015. 92 p. (In Russian).
30. Dyakonov VV. Matlab 6: Tutorial. Saint-Petersburg: Piter; 2002. 672 p. (In Russian).
31. Burakov MV. Neural networks and neurocontrollers: textbook. Saint-Petersburg: GUAP; 2013. 284 p. (In Russian).
32. Kovalev SM, Khatlamadzhyan AE. Modeling artificial neural networks in MATLAB environment: Study guide for laboratory work. Rostov. St. University of Railway Transport. Rostov; 2008. 35 p. (In Russian).
33. Medvedev VS, Potemkin VG. Neural networks. Matlab 6. Moscow: Dialog-MEPhI; 2002. 496 p. (In Russian).
34. Nikolaev SV, Bazhenov RI. Pattern recognition using neural networks in the MatlabR2009b environment. 2015. No. 13 (13-2015). Available from: <http://nauka-rastudent.ru/13/2355/> [Accessed October 20, 2020]. (In Russian).

Received: October 26, 2020

**For correspondence: Viktor S. Repin** – Doctor of Biological Sciences, Head of the Ecology Laboratory, Saint-Petersburg Research Institute of Radiation Hygiene after Professor P.V. Ramzaev, Federal Service for Surveillance on Consumer Rights Protection and Human Well-Being (Mira str., 8, Saint-Petersburg, 197101, Russia; E-mail: v.repin@mail.ru)

**For citation: Repin V.S. Study of the possibility of using an artificial neural network to recognize and assess the contribution of individual radionuclides to the total beta spectrum. *Radiatsionnaya Gygiena = Radiation Hygiene*. 2020. Vol. 13, No. 4. P. 74-81. (In Russian). DOI: 10.21514/1998-426X-2020-13-4-74-81**