

Применение нейросетевого подхода к измерениям потоков космического излучения

А. Ю. ИСТРАТОВ¹, К. В. ЗАХАРЧЕНКО², А. Ф. КАПЕРКО¹, В. А. КОЛЮБИН²,
В. П. КУЛАГИН¹, Р. И. КУРОЧКИН¹

¹ Московский институт электроники и математики НИУ ВШЭ,
Москва, Россия, e-mail: aistratov@hse.ru

² Производственно-технологический центр «УралАлмазИнвест»,
Москва, Россия, e-mail: nanophys@mail.ru

Рассмотрен нейросетевой подход к обработке выходной информации спектрометра на алмазных детекторах, используемого на борту космического корабля. Предложен математический инструментальный, позволяющий получать дифференцируемую информацию о потоках электронов, протонов и тяжёлых заряженных частиц в 21 энергетическом диапазоне.

Ключевые слова: спектрометр, космическое излучение, нейронная сеть, алмазный детектор, космический аппарат, восстановление спектра.

A neural network approach is considered for the processing of the output information from a spectrometer working on diamond detectors, mounted on board a spacecraft. A mathematical tool is suggested, allowing to receive differentiable information about the flow of electrons, protons and heavy charged particles in the range of power 21.

Key words: spectrometer, cosmic radiation, a neural network, a diamond detector, spacecraft, spectrum recovery.

Для непрерывного мониторинга радиационной обстановки на борту космических аппаратов (КА), осуществляющих длительные космические миссии, необходимо использование приборов, позволяющих фиксировать спектральный состав и интенсивность космического излучения (КИ).

В связи с увеличением длительности жизненного цикла КА до 20 лет и возрастанием дозовых нагрузок излучения на детекторы спектрометра применение алмазных детекторов для регистрации КИ становится безальтернативным. Однако использование таких детекторов в спектрометрических приборах КИ имеет специфические особенности и требует специальных решений для обработки данных [1, 2].

В статье рассмотрены вопросы применения искусственной нейронной сети (ИНС) для обработки данных спектрометра КИ на алмазных детекторах. Это позволяет получить текущие значения плотностей потоков электронов, протонов и тяжёлых заряженных частиц (ТЗЧ) по 21 энергетическому диапазону. Для учета радиационной обстановки на борту КА предполагается использовать устройство с пятью алмазными детекторами [3]. При попадании ионизирующей частицы КИ в алмазный детектор в нём возникает электрический заряд Q , пропорциональный энергии E , потерянной частицей. Выходной сигнал каждого прибора усиливается с помощью отдельного зарядочувствительного устройства, на выходе которого появляются импульсы напряжения с амплитудой, пропорциональной заряду, а, следовательно, энергии, переданной частицей детектору. Выходные сигналы зарядочувствительных усилителей с помощью аналого-цифрового преобразования сортируются по амплитудным уровням на несколько диапазонов. В цифровой схеме спектрометра с помощью 24 счётчиков

С1-1 — С5-4 подсчитываются частицы КИ, сигналы от которых превысили соответствующие амплитудные уровни [2]. Перед каждым алмазным детектором установлена металлическая пластина заданной толщины — селективный фильтр. Проходя через материал фильтра, ионизирующая

Таблица 1

Выходные показатели, регистрируемые в счётчиках спектрометра

Детектор	Счётчик частиц	Диапазон энергий регистрируемых частиц		
		Электроны, МэВ	Протоны, МэВ	ТЗЧ, МэВ/нуклон
1	C1-1	0,3—0,9; более 6	более 4,6	более 4,6
	C1-2	—	4,6—160	более 4,6
	C1-3	—	4,7—80	более 4,6
	C1-4	—	5,3—30	более 4,6
	C1-5	—	7,6—15	более 4,8
2	C2-1	0,65—1,5; более 4,8	более 12,5	более 12,5
	C2-2	—	12,5—250	более 12,5
	C2-3	—	12,5—80	более 12,5
	C2-4	—	13—35	более 12,5
	C2-5	—	14—21	более 12,5
3	C3-1	более 1,55	более 25	более 25
	C3-2	более 3,4	более 25	более 25
	C3-3	—	25—300	более 25
	C3-4	—	25—100	более 25
	C3-5	—	25—60	более 25
4	C4-1	более 4,9	более 49	более 49
	C4-2	более 12,5	более 49	более 49
	C4-3	—	49—400	более 49
	C4-4	—	49—150	более 49
	C4-5	—	50—110	более 49
5	C5-1	—	—	более 45
	C5-2	—	—	более 58
	C5-3	—	—	85—220
	C5-4	—	—	120—185

частица теряет часть энергии, что приводит к смещению спектра поглощения энергии в детекторе. В результате за время цикла измерений в счётчиках спектрометра фиксируется информация о количестве частиц соответствующего энергетического диапазона.

В табл. 1 приведены диапазоны энергий космических частиц (электронов, протонов и ТЗЧ), которые регистрируются в соответствующих счётчиках спектрометра.

Скорости счёта определяются энергиями космических частиц: минимальной, необходимой для прохождения селективного фильтра, и передаваемой алмазному детектору. Нелинейный характер зависимости энергии, передаваемой алмазному детектору, от исходной энергии частиц приводит к тому, что скорость счёта в С1-1 пропорциональна потокам электронов с энергиями 0,3—0,9 МэВ, энергиями, большими 6 МэВ, а также потокам протонов и ТЗЧ с энергиями более 4,6 МэВ/нуклон. Счётчики С1-2, С1-3, С1-4, С1-5 не срабатывают при воздействии электронов вне зависимости от их энергии. В счётчике С2-1 регистрируются электроны с энергиями 0,65—1,5 МэВ и более 4,8 МэВ.

Из табл. 1 следует, что спектрометр за один цикл измерений позволяет получить количественную информацию о потоках электронов, протонов и ТЗЧ в энергетическом диапазоне 0—10000 МэВ. Однако информация о частицах, содержащаяся в каждом счётчике, является суммарным значением всех потоков. Счётчики спектрометра регистрируют все частицы, прибор не различает их по видам.

Скорость счёта каждого прибора является функцией потоков электронов, протонов и ТЗЧ с различными энергиями. Например, скорость счёта С3-1 пропорциональна сумме потоков электронов с энергиями больше 1,55 МэВ, протонов — более 25 МэВ, ТЗЧ — более 25 МэВ/нуклон, т. е. счётчики С1-1 — С5-4 накапливают информацию и об электронах, и о протонах, и о ТЗЧ. Для использования информации в системах управления КА необходимо по данным спектрометра определять отдельные значения потоков КИ по энергетическим диапазонам Э1—Э8, П1—П8, Т1—Т5, представленным в табл. 2, 3.

Таблица 2

Энергетические диапазоны для потоков электронов, протонов

Поток	Диапазон энергий, МэВ	Диапазон спектра
Электроны	0,2—0,5	Э1
	0,5—0,8	Э2
	0,8—1,2	Э3
	1,2—1,6	Э4
	1,6—2,1	Э5
	2,1—3,0	Э6
	3,0—5,0	Э7
	5,0—7,0	Э8
Протоны	0,2—10	П1
	10—16	П2
	16—25	П3
	25—35	П4
	35—50	П5
	50—100	П6
	100—200	П7
	200—10000	П8

Таблица 3

Энергетические диапазоны для потоков тяжёлых заряженных частиц

Поток	Диапазон линейных передач энергии, МэВ · см ² /мг	Диапазон спектра
ТЗЧ	0,01—1	Т1
	1—3	Т2
	3—10	Т3
	10—30	Т4
	30—80	Т5

Задачу можно решить при использовании прямого подхода, заключающегося в формировании системы разностных алгебраических уравнений. Такая система по показателям счётчиков позволяет получить отдельные значения зарегистрированных частиц в указанных диапазонах. Например, по показаниям С1-5, С2-5, С3-5, С4-5, С5-1—С5-4 можно найти количество частиц, относящихся к ТЗЧ, и далее по математической модели измерительного тракта спектрометра рассчитать плановые показатели всех счётчиков, соответствующих регистрации ТЗЧ. Эти данные фиксируются и вычитаются из общих показателей для расчёта оставшегося количества электронов и протонов. В результате получается громоздкая вычислительная схема, качество и адекватность которой определяются математической моделью. Решение задачи можно трактовать как построение модели выходной информации спектрометра, затем на её основе преобразовывать дискретные величины в непрерывные с образованием области точек, принадлежащих порождающему источнику, но не вошедших в интервал наблюдений [3]. Фактически — это задача аппроксимации многомерной функции в указанном диапазоне измеряемых параметров. Её можно решать с помощью различных математических методов, например полиномиальной аппроксимацией [4], сплайн аппроксимацией [5] и др. При этом необходимо учитывать вероятность случайных «всплесков» электронной и (или) протонной активности, что, скорее всего, приведёт либо к значительной погрешности вычислений, либо к большой размерности и сложности. В этом случае задача наиболее эффективно решается на базе теории ИНС [6—8].

Использование нейросетевой технологии обеспечивает не только адекватное отображение модели исследуемого процесса или явления, возможность нахождения закономерностей в большом потоке противоречивой информации, сохранение связей между важными факторами, но и высокую скорость обработки данных и малую ресурсоёмкость вычислительного оборудования. Дополнительным преимуществом этого подхода является возможность решения представленной задачи в едином вычислительном базисе.

Для восстановления спектров КИ в окружающей среде КА требуется построить и обучить нейросетевую модель (НМ), формирующую по известному входному сигналу выходной сигнал, а также проверить адекватность построенной НМ на данных, по которым она не обучалась. Формализация этой постановки выглядит следующим образом. Входной сигнал — значения измеренных параметров спектрометра, задаётся вектором $\mathbf{X} = \{x_i; i = 0, 1, 2, \dots, N\}$; $N = 24$ — количество нейронов во входном слое. Выходной сигнал — значения восстановленных параметров спектра КИ, задаётся векто-

ром $Y = \{y_i; i = 1, 2, \dots, K\}$; $K = 21$ — количество нейронов в выходном слое. Выходной сигнал включает по 8 значений параметров восстановленного спектра потоков электронов и протонов и 5 значений параметров восстановленного спектра потоков ТЗЧ. Существует соответствие между векторами входного и выходного сигналов — обучающая выборка. В табл. 4 содержатся примеры «вход-выход», на которых НМ будет обучаться и тестироваться.

Среди большого разнообразия современных нейросетевых подходов наиболее применимы для решения поставленной задачи парадигмы многослойного персептрона и базисно-радиальной сети [7, 9, 10]. На первом этапе исследований задачу предлагается решать на базе персептрона с одним скрытым слоем. Выбор такой нейросетевой парадигмы обосновывается следствием теоремы Колмогорова, где утверждается, что «с помощью персептрона с одним скрытым слоем можно аппроксимировать любую сколь угодно сложную функцию с любой наперед заданной точностью» [10]. Структура персептрона с одним скрытым слоем представлена на рис. 1.

Нейронная сеть включает три слоя нейронов: входной, скрытый и выходной. В качестве входных данных $\tilde{X} = \{\tilde{x}_i; i = 1, 2, \dots, N\}$ используются предварительно обработанные выходные параметры счётчиков С1-1—С5-4. Весовым коэффициентам (матрицы $\bar{W}1, \bar{W}2$) первоначально присваиваются случайные значения из интервала $-0,5 \dots +0,5$, $N = 24$, $K = 21$:

$$\bar{W}1 = \{w1_{i,j}; i = 0, 1, 2, \dots, N; j = 1, 2, \dots, H1\};$$

$$\bar{W}2 = \{w2_{j,k}; j = 0, 1, 2, \dots, H1; k = 1, 2, \dots, K\},$$

где $H1$ — количество нейронов в скрытом слое.

На рис. 1 обозначено: $\text{Вых}1_i$ ($i = 0, 1, \dots, H1$), $\tilde{y}_j$ ($j = 0, 1, \dots, K$) — значения выходов нейронов со скрытого и выходного слоёв, соответственно; f_a — нелинейное преобразование сигнала сети, т. е. функция активации. С учётом введенных обозначений выход с j -го нейрона скрытого слоя при $j = 1, 2, \dots, H1$ определяется как

$$\text{Вых}1_j = f_a \left(\sum_{i=0}^N w1_{i,j} \tilde{x}_i \right), \quad (1)$$

а выход с j -го нейрона выходного слоя при $j = 1, 2, \dots, K$ имеет вид

$$\tilde{y}_j = f_a \left(\sum_{i=0}^{H1} w2_{i,j} \text{Вых}1_i \right). \quad (2)$$

Представленную структуру нейросетевой модели обозначим НМ ($N:H1:K$). Если через $\tilde{Y}^* = \{\tilde{y}_j^*; j = 1, 2, \dots, K\}$ обозначить ожидаемый выход сети, т. е. ожидаемый вектор $\tilde{Y}$, то ошибку системы для заданного входного сигнала (рассогла-




Рис. 1. Структура персептрона с одним скрытым слоем

сование реального и ожидаемого выходного сигналов) можно записать в следующем виде:

$$e_k = \tilde{y}_k - \tilde{y}_k^* = f_a \left[\sum_{j=0}^{H1} w2_{j,k} f_a \left(\sum_{i=0}^N w1_{i,j} \tilde{x}_i \right) \right] - \tilde{y}_k^*, \quad k = 1, 2, \dots, K.$$

Используем в качестве функционала оптимизации критерий минимума среднеквадратической функции ошибки $F(w)$, а в качестве функции активации — сигмоидальную функцию:

$$F(w) = \frac{1}{2P} \sum_k e_k^2 = \frac{1}{2P} \sum_{k=1}^P (\tilde{y}_k - \tilde{y}_k^*)^2; \quad (3)$$

$$f_a(x) = 1 + e^{-(x+\Theta)/\Theta_0},$$

где P — количество обучающих примеров; параметры Θ_0 , Θ следует выбирать экспериментально; производная этой функции $f'_a = f_a(1-f_a)/\Theta_0$.

Теперь можно приступить к этапу обучения нейронной сети, заключающемуся в нахождении весовых коэффициентов $\bar{W}1, \bar{W}2$, при которых функционал ошибки НМ из (3) не будет превышать заданную точность $\varepsilon \ll 1$ для всех предъявленных примеров.

После обучения НМ на любой входной сигнал $\tilde{X}$ будет формировать выходной сигнал $\tilde{Y}$ в соответствии с (1), (2). Обучение НМ — это процедура, не относящаяся к функционированию прибора. Главное её назначение — определить параметры НМ, такие как количество слоёв и нейронов, значения $\bar{W}1, \bar{W}2$ и др. Поэтому первоначально необходимо задать прототип НМ, т. е. количество слоёв и нейронов в них, а после приступить к настройке весовых коэффициентов. Выбор прототипа НМ обоснован, с одной стороны, требованиями качества выхода, при которых относительная погреш-

ность формируемых показаний прибора не должна превышать 10 %, с другой стороны — простотой реализации, так как чем меньше слоёв и нейронов в слоях, тем проще реализация и обучение, выше надёжность. Определение прототипа НМ относится к этапу экспериментальных исследований, следовательно, эта процедура, а также обучение НМ и проверка её на адекватность проводятся для каждого экспериментального образца моделей. Для обучения НМ необходимо определить алгоритм минимизации функционала ошибки НМ из (3). Для решения данной задачи можно использовать градиентные, стохастические, генетические алгоритмы и др. [9, 11, 12].

В проведённых исследованиях использовали градиентный алгоритм наискорейшего спуска. Весовые коэффициенты на каждом шаге обучения t определяли из соотношения

$\bar{W}^{t+1} = \bar{W}^t - \eta^t \frac{\partial F}{\partial \bar{W}^t}$, где $\eta^t \frac{\partial F}{\partial \bar{W}^t} = \Delta \bar{W}^t$ — градиент ошибки; η^t — коэффициент, характеризующий скорость и качество обучения НМ.

Выражения для изменения весовых коэффициентов рассчитывали для каждого примера из обучающей выборки:

$$w1_{ij} = w1_{ij} + \Delta w1_{ij}, i = 0, 1, 2, \dots, N;$$

$$w2_{jk} = w2_{jk} + \Delta w2_{jk}, j = 0, 1, 2, \dots, H1; k = 1, 2, \dots, K;$$

$$\delta_k = \tilde{y}_k (1 - \tilde{y}_k) (\tilde{y}_k^* - \tilde{y}_k) / \Theta_0; \Delta w2_{0k} = \eta \delta_k; \Delta w2_{jk} = \eta \delta_k \text{Вых}1_j;$$

$$\delta1_j = \text{Вых}1_j (1 - \text{Вых}1_j) \sum_{k=1}^K w2_{jk} \delta_k / \Theta_0; \Delta w1_{0j} = \eta \delta1_j;$$

$$\Delta w1_{ij} = \eta \delta1_j \tilde{x}_i.$$

Начальные значения весовых коэффициентов определяли последовательностью действий [7]:

инициализация предварительных значений компонент матриц $\bar{W}1, \bar{W}2$ случайными равномерно распределёнными числами из интервала $-0,5 \dots +0,5$;
вычисление норм

$$\|w1_i\| = \sqrt{w1_{i1}^2 + w1_{i2}^2 + \dots + w1_{iH1}^2};$$

$$\|w2_j\| = \sqrt{w2_{j1}^2 + w2_{j2}^2 + \dots + w2_{jK}^2};$$

расчёт коэффициентов масштабирования $\beta = 0,7 \sqrt{m}$, где n, m — количество нейронов текущего и последующего слоев, соответственно;

выбор смещений $w1_{0j}, w2_{0k}, (j = 0, 1, 2, \dots, H1; k = 1, 2, \dots, K)$ из интервала $-\beta, \dots, \beta$;

формирование начальных весовых коэффициентов:

$$w1_{ij} = \beta_1 w1_{ij} / \|w1_i\|, w2_{jk} = \beta_2 w2_{jk} / \|w2_j\|.$$

Так как при обучении НМ на базе наискорейшего градиентного спуска возможны «зависания» в локальных минимумах функционала (3), использовали плавающий коэффициент (шаг) обучения η . Начальный коэффициент выбирали $\eta = 0,75$. Значения весов и смещений сети запоминались. Если после 10 итераций (этапов обучения) функционал ошибки продолжал уменьшаться, то η увеличивался на 0,05, а текущие значения весов и смещений запоминались. Если

на некоторой итерации произошло увеличение функционала (3), то последние запомненные значения весов и смещений восстанавливались, коэффициент η уменьшался на 0,05 и процесс обучения продолжался до тех пор, пока функционал (3) не становился меньше заданной точности ϵ , или дальнейшие итерации не приводили к уменьшению значения (3).

Для проведения экспериментальных исследований был разработан программный комплекс, позволяющий формировать и изменять конструктив НМ, проводить её обучение и тестирование, получать расчётные результаты и отображать их визуально и в виде таблиц. Фрагменты интерфейса программного комплекса представлены на рис. 2, 3 и в табл. 4, 5. На рис. 2 изображены ожидаемый и смоделированный ИНС сигналы. Заметим, что сеть смогла подстроиться под ожидаемый сигнал.

Эффективность построенной НМ в первую очередь определяется качеством и количеством примеров для обучения, охватывающих весь измеряемый диапазон КИ и включающих все возможные, в том числе и внештатные, ситуации. Чем больше примеров будет предоставлено нейронной сети, тем более адекватную модель удастся построить. Для формирования данных для обучения и тестирования было подготовлено 1000 примеров. Измерительные данные спектрометра КИ получили с помощью компьютерной модели при преобразовании спектров ионизирующих излучений естественных радиационных поясов Земли, солнечных и галактических космических лучей. Спектры КИ определяли согласно стандарту [13] для различных орбит и разного уровня солнечной активности. Были рассчитаны плотности потока для изотропных потоков электронов, протонов и ТЗЧ в диапазонах энергии и линейной передачи энергии, границы которых указаны в табл. 2, 3, а в табл. 4 приведены примеры таких данных по спектрам 201, 202, 203. Чтобы НМ быстрее обучалась, значения входного X и ожидаемого выходного сигнала Y^* подвергались масштабированию в интервале (0, 1):

$$\tilde{x}_i = (x_i - x_{i\min}) / (x_{i\max} - x_{i\min}); i = 0, 1, 2, \dots, N; k = 1, 2, \dots, K;$$

$$\tilde{y}_k^* = (\tilde{y}_k^* - \tilde{y}_{k\min}^*) / (\tilde{y}_{k\max}^* - \tilde{y}_{k\min}^*);$$

$$i = 0, 1, 2, \dots, N; k = 1, 2, \dots, K,$$

где $x_i, \tilde{x}_i$ — исходное и масштабируемое значения i -й компоненты входного сигнала, соответственно; $x_{i\min}, x_{i\max}$ — минимальное и максимальное значения i -й компоненты входного сигнала; $y_k^*, \tilde{y}_k^*$ — значение k -й компоненты желаемого выходного сигнала и её масштабируемое значение, соответственно; $y_{k\min}^*, y_{k\max}^*$ — минимальное и максимальное значения k -й компоненты желаемого выходного сигнала, соответственно.

Проанализировав табл. 1—4, можно определить некоторые параметры НМ. Обучающую выборку делили на две части: $P = 800$ примеров использовали для обучения нейронной сети (обучающее множество), а оставшиеся 200 примеров — для тестирования (тестовое множество). Примеры из обучающего множества равномерно перемешивались. Размерность входного сигнала $N = 24$, а выходного $K = 21$. Первоначально количество нейронов в скрытом слое выбирали $H1 = 80$, но такое количество нейронов не позволило обучить НМ до значения $\epsilon \leq 0,1$, т. е. с погрешностью менее 10 %.

Таблица 4

Фрагмент обучающей и тестовой выборки для искусственной нейронной сети

Счётчик частиц КИ	Скорости счёта по спектрам (с ⁻¹) (наблюдаемый выходной сигнал)			Энергетические диапазоны для частиц КИ	Плотность потока, см ⁻² · с ⁻¹ , по спектрам (ожидаемый выходной сигнал)		
	201	202	203		201	202	203
C1-1	8,12·10 ²	4,45·10 ²	6,63·10 ²	Э-1	5,94·10 ⁶	4,08·10 ⁶	5,65·10 ⁶
C1-2	3,66·10 ⁻¹	1,25·10 ²	1,19·10 ⁻¹	Э-2	1,69·10 ⁶	4,45·10 ⁵	1,15·10 ⁶
C1-3	2,84·10 ⁻¹	93,10	9,49·10 ⁻²	Э-3	5,33·10 ⁵	9,26·10 ⁴	2,64·10 ⁵
C1-4	1,62·10 ⁻¹	49,30	5,59·10 ⁻²	Э-4	6,64·10 ⁴	6,42·10 ³	1,50·10 ⁴
C1-5	2,98·10 ⁻²	7,07	1,08·10 ⁻²	Э-5	3,26·10 ⁴	3,50·10 ³	1,01·10 ³
C2-1	4,08·10 ²	1,07·10 ²	2,28·10 ²	Э-6	4,01·10 ⁴	4,81·10 ³	7,78·10 ²
C2-2	2,12·10 ⁻¹	22,60	7,74·10 ⁻²	Э-7	5,63·10 ⁴	7,99·10 ³	8,95·10 ²
C2-3	1,57·10 ⁻¹	18,00	5,98·10 ⁻²	Э-8	2,68·10 ⁴	4,82·10 ³	3,20·10 ²
C2-4	8,54·10 ⁻²	10,50	3,31·10 ⁻²	П-9	2,14·10 ⁶	3,30·10 ⁷	4,60·10 ⁵
C2-5	1,49·10 ⁻²	1,65	5,85·10 ⁻³	П-10	62,60	1,42·10 ⁴	23,20
C3-1	1,11·10 ³	2,31·10 ²	1,66	П-11	26,01	3,02·10 ³	10,10
C3-2	1,48	27,70	2,04·10 ⁻¹	П-12	8,51	5,67·10 ²	3,10
C3-3	4,46·10 ⁻¹	20,60	1,36·10 ⁻¹	П-13	4,63	1,93·10 ²	1,34
C3-4	1,97·10 ⁻¹	10,50	6,63·10 ⁻²	П-14	4,90	73,30	7,25·10 ⁻¹
C3-5	3,73·10 ⁻²	1,88	1,32·10 ⁻²	П-15	2,93	6,78	1,33·10 ⁻¹
C4-1	8,62·10 ²	2,58·10 ²	6,95	П-16	4,53	1,99	1,59
C4-2	2,58·10 ⁻¹	2,20	3,24·10 ⁻²	Т-17	8,04	16,4	3,14
C4-3	9,99·10 ⁻²	1,28	1,62·10 ⁻²	Т-18	1,48·10 ⁻¹	3,13·10 ⁻¹	5,73·10 ⁻²
C4-4	3,07·10 ⁻²	4,61·10 ⁻¹	5,89·10 ⁻³	Т-19	1,02·10 ⁻¹	2,16·10 ⁻¹	3,84·10 ⁻²
C4-5	5,87·10 ⁻³	7,05·10 ⁻²	1,55·10 ⁻³	Т-20	2,12·10 ⁻²	4,51·10 ⁻²	8,10·10 ⁻³
C5-1	3,28·10 ⁻⁵	1,57·10 ⁻⁵	1,49·10 ⁻⁵	Т-21	1,06·10 ⁻¹⁰	2,88·10 ⁻¹²	3,74·10 ⁻¹²
C5-2	2,03·10 ⁻⁶	5,25·10 ⁻⁷	5,64·10 ⁻⁷	—	—	—	—
C5-3	8,72·10 ⁻⁸	2,03·10 ⁻⁸	2,22·10 ⁻⁸	—	—	—	—
C5-4	2,72·10 ⁻¹⁰	5,93·10 ⁻¹¹	7,44·10 ⁻¹¹	—	—	—	—

Таблица 5

Фрагмент сравнительных показателей ожидаемого выхода и выхода искусственной нейронной сети для примеров 22 и 49 из тестового множества

Энергетические диапазоны для частиц КИ	Ожидаемый сигнал, см ⁻² · с ⁻¹	Погрешность, %	Сигнал сети, см ⁻² · с ⁻¹	Ожидаемый сигнал, см ⁻² · с ⁻¹	Погрешность, %	Сигнал сети, см ⁻² · с ⁻¹
Э-1	269000000	0,10	268543726	12100000	4,6	12661872
Э-2	23200000	0,07	23218032	3520000	0,1	3525374
Э-3	948000	10,00	848341	676000	10,0	605111
Э-4	158000	2,00	161646	49400	6,7	46076
Э-5	71000	6,00	75323	38200	6,6	35630
Э-6	36900	10,00	40665	52100	4,7	54546
Э-7	26100	2,00	25491	83400	4,0	86847
Э-8	7620	0,30	7592	47600	0,4	47406
П-9	182000	9,00	165640	75500000	1,3	74524819
П-10	30600	4,00	29296	37800	3,9	36330
П-11	20200	0,90	20020	25100	1,7	24668
П-12	9430	1,00	9558	12300	1,0	12429
П-13	6990	0,70	7037	7990	1,4	8106
П-14	8090	5,50	7637	7580	7,0	8117
П-15	4890	3,80	5076	2810	10,0	3094
П-16	2560	5,00	2683	1530	9,0	1668
Т-17	9,28	8,00	10,020	1580	7,0	1692
Т-18	0,17	6,00	0,180	24,7	7,7	26,6
Т-19	0,11	9,00	0,120	10,2	8,8	11,1
Т-20	0,02	10,00	0,018	2,5	8,0	2,7
Т-21	6·10 ⁻¹³	8,00	6,5·10 ⁻¹³	1·10 ⁻¹¹	10,0	9·10 ⁻¹²

После 3 млн. итераций обучения удалось добиться требуемой точности, увеличив количество нейронов в скрытом слое $H1$ до 300. Возможно, добавление второго скрытого слоя позволит повысить эффективность НМ.

Так как выход НМ $\tilde{Y}$ ограничен интервалом (0, 1), то он может быть преобразован в реальный выходной сигнал Y в соответствии с выражением $y_k = \tilde{y}_k (y_{k \max} - y_{k \min}) + y_{k \min}$, $k = 1, 2, \dots, K$. Нейронную модель НМ (24:300:21) тестировали на выборке из 50 произвольных примеров тестового множества. После обучения НМ ей предъявлялись эти примеры. В данном случае в ИНС содержится 24 нейрона входного, 300 нейронов скрытого и 21 нейрон выходного слоёв. Для оценки качества восстановления спектров КИ для каждого энергетического диапазона вычисляли относительную погрешность между выходом сети и желаемым выходным сигналом.

Данные о погрешностях по всем 50 примерам сведены в табл. 5, из которой следует, что компоненты преобразованного выходного вектора Y , смоделированного ИНС, не превышают погрешности в 10 %. Результаты графического мониторинга восстановления спектров КИ по выходному параметру П9 (протоны) и значения средних абсолютных погрешностей по всем выходам сети для указанных примеров представлены на рис. 3.




Рис. 2. Значения U ожидаемых (а) и полученных (б) спектров сигналов космического излучения




Рис. 3. Гистограммы средних абсолютных погрешностей по выходам сети

Заключение. В ходе исследования была разработана НМ и показаны возможности восстановления дифференцируемых спектров электронного, протонного и ТЗЧ излучений по показаниям спектрометра на алмазных детекторах для космических аппаратов в энергетическом диапазоне 0—10000 МэВ. Реализовано программное обеспечение для её обучения и тестирования. Проведённые эксперименты подтвердили эффективность применения нейросетевой технологии для восстановления спектров КИ. Относительная погрешность восстановления не превысила 10 %.

Работа выполнена при поддержке Минобрнауки России (уникальный идентификатор RFMEFI 60514X0001).

Литература

1. Кадилин В. В., Колюбин В. А., Львов С. А., Недосекин П. Г., Идалов В. А., Тюрин Е. М., Колесников С. В., Самосадный В. Т. Перспективы применения алмазных детекторов для регистрации заряженных частиц космического излучения // Ядерная физика и инженеринг. 2014. Т. 5. № 2. С. 138.
2. Захарченко К. В., Каперко А. Ф., Колюбин В. А., Кулагин В. П., Львов С. А., Недосекин П. Г., Чумаченко Е. Н. Спектрометрический алмазный детектор потоков ионизирующего излучения для транспортных космических систем // Измерительная техника. 2015. № 6. С. 63—67.
3. Аневский С. И., Золотаревский Ю. М., Крутиков В. Н., Минаева О. А., Минаев Р. В., Сенин Д. С. Развитие методов воспроизведения и передачи единиц спектрометрии с использованием синхротронного излучения // Измерительная техника. 2015. № 3. С. 31—34.
4. Дикусар Н. Д. Полиномиальная аппроксимация высоких порядков. Дубна: ОИЯИ, 2014.
5. Алберг Дж., Нильсон Э., Уолш Дж. Теория сплайнов и её приложения / Пер. с англ. М.: Мир, 1972.
6. Хайкин Саймон. Нейронные сети: полный курс. М.: Издательский дом «Вильямс», 2006.
7. Murray A. F. Application of Neural Nets. Kluwer Academic Publishers, 1995.
8. Клеопин А. В. Уменьшение погрешности измерений длительности фронта импульсов с использованием искусственной нейронной сети // Измерительная техника. 2015. № 4. С. 58—60.
9. Fausett L. Fundamentals of Neural Networks: Architectures, Algorithms and Applications. Prentice Hall, 1994.
10. Колмогоров А. Н., Фомин С. В. Элементы теории функций и функционального анализа. М.: ФиС, 1976.
11. Панченко Т. В. Генетические алгоритмы: Учебно-методическое пособие / Под ред. Ю. Ю. Тарасевича. Астрахань: АГУ, 2007.
12. Круглов В. В., Дли М. И., Голунов Р. Ю. Нечеткая логика и искусственные нейронные сети. М.: ФИЗМАТЛИТ, 2001.
13. ОСТ 134-1044—2007. Аппаратура, приборы, устройства и оборудование космических аппаратов. Методы расчёта радиационных условий на борту космических аппаратов и установления требований по стойкости радиоэлектронной аппаратуры космических аппаратов к воздействию заряженных частиц космического пространства естественного происхождения.

Дата принятия 20.10.2015 г.