

doi: 10.7690/bgzdh.2022.03.018

## 基于人工神经网络的核素识别方法

贺楠<sup>1,2</sup>, 吕会议<sup>1</sup>, 王波<sup>3</sup>, 何嵘<sup>1</sup>, 竹文坤<sup>1</sup>, 袁长迎<sup>1</sup>

(1. 西南科技大学国防科技学院, 四川 绵阳 621010;

2. 中国兵器装备集团自动化研究所有限公司, 四川 绵阳 621000;

3. 陆军装备部驻重庆地区军事代表局驻成都地区第一军代室, 成都, 611930)

**摘要:** 针对传统核素识别方法不具有强适应性导致识别率降低的问题, 建立基于反向传播(back propagation, BP)神经网络的核素识别预测模型。以镅、镉、钚、氡、钷、钴、铯 7 种核素的实测信号为例进行仿真模拟, 建立核素识别模型。结果表明: 该模型能快速准确地识别上述核素, 应用前景广泛。

**关键词:** BP 神经网络; 核素; 核素识别; 信号

**中图分类号:** TJ91 **文献标志码:** A

## Nuclide Identification Method Based on Artificial Neural Network

He Nan<sup>1,2</sup>, LYU Huiyi<sup>1</sup>, Wang Bo<sup>3</sup>, He Rong<sup>1</sup>, Zhu Wenkun<sup>1</sup>, Yuan Changying<sup>1</sup>

(1. School of National Defense Science and Technology, Southwest University of Science and Technology, Mianyang 621010, China; 2. Automation Research Institute Co., Ltd. of China South Industries Group Corporation, Mianyang 621000, China; 3. No. 1 Military Representative Office in Chengdu, Military Representative Bureau of Army Equipment Department in Chongqing, Chengdu 611930, China)

**Abstract:** In order to solve the problem that the recognition rate of traditional nuclide recognition methods is low due to the lack of strong adaptability, a nuclide recognition prediction model based on back propagation (BP) neural network is established. Taking the measured signals of seven nuclides of Americium, Cadmium, Plutonium, Radon, Palladium, Cobalt and Cesium as an example, the nuclide identification model is established. The results show that the recognition model can quickly and accurately identify the above nuclides, and has a broad application prospect.

**Keywords:** BP neural network; nuclide; identification nuclide; signal

### 0 引言

当前, 核素的分类识别是人工智能在工业领域应用的研究热点。在实际测量环境中, 放射性核素经过  $\gamma$  能谱仪等核物理设备仪器进行探测, 探测器接收发射的  $\gamma$  射线源生成能谱数据, 获取的能谱通过特定的方法进行分析。目前, 传统的核探测解谱方法有全能峰法<sup>[1-3]</sup>、逐次差引法<sup>[4-5]</sup>、逆矩阵法<sup>[6]</sup>、最小二乘法<sup>[7-8]</sup>等。由于传统的  $\gamma$  能谱信息的解谱不能涵盖全部峰值、能谱信息具有局部特征、存在重叠峰等情况, 导致能谱解析出来的核素种类出现错失、误判的情况。另外, 核素能谱随测量环境发生动态改变, 传统识别方法不具有强适应性, 识别率会降低。神经网络算法可以构造复杂的非线性关系, 具有很强的自学习能力, 是进行信息预测的常用模块。笔者基于神经网络中的反向传播(BP)算法, 利用 Mathcad 编制程序, 以镅、镉、钚、氡、钷、钴、铯 7 种核素的能谱数据作为网络的训练样本, 进行

仿真, 建立核素预测识别模型, 并以另一组完全独立的核能谱数据为测试样本对上述预测模型的可靠性进行检验。

### 1 基本原理

#### 1.1 神经网络简介

人工神经网络(artificial neural network, ANN)是模仿生物大脑结构和功能而构成的一种信号处理系统。它具有信息分布存储、并行处理、自学习、自组织等特点以及优良的非线性逼近和较好的容错性, 在信息处理、模式识别、智能控制等领域得到了广泛的应用<sup>[9]</sup>。

实际应用中, 绝大部分人工神经网络采用 BP 网络模型。误差反向传播算法的基本思想: 利用实际输出与期望值之差对网络各层的连接权重由后向前逐层进行校正<sup>[10-13]</sup>。BP 神经网络的优点: 只要有足够多的隐藏层和节点数, 网络就可以无限逼近任意的非线性映射。

收稿日期: 2021-12-23; 修回日期: 2022-01-04

基金项目: 四川省科技厅自然科学基金(2019ZDZX0027, 2019YFG0514, 2020YFG0147)

作者简介: 贺楠(1985—), 男, 安徽人, 硕士, 工程师, 从事信息系统与信息管理、项目管理、核探测技术研究。

E-mail: 378861650@qq.com.

### 1.2 网络的拓扑结构

神经网络的拓扑结构如图 1 所示。网络包含若干“层”，每一层又包含有若干“节点”（神经元）。信号位于各个节点上并由前向后在层与层之间进行传输。顺着信号的传输方向看，神经网络的各个“层”分别称为输入层、隐藏层和输出层。输入层是信号进入到神经网络的地方，输入层后面是隐藏层，最后一层为输出层。通常神经网络的结构中有且仅有一个输入层和一个输出层，而隐藏层可以是一层或多层。经验表明，通常只要数据结构不是异常庞大，单层隐藏层都可以取得良好的效果。这样的网络称为三层神经网络，是实际应用中最为普遍的情况。




图 1 神经网络的拓扑结构

### 1.3 信号的正向传输

用  $n_i$ 、 $n_h$ 、 $n_o$  分别表示输入层、隐藏层和输出层的节点数。进入输入层各节点的信号可以用一个列向量表述：

$$I = \begin{pmatrix} I_1 \\ I_2 \\ \vdots \\ I_{n_i} \end{pmatrix} \quad (1)$$

输入层与隐藏层之间的传输因子顺序地排列起来，构成传输矩阵：

$$W_{i-h} = \begin{pmatrix} w_{1,1} & w_{2,1} & \cdots & w_{n_i,1} \\ w_{1,2} & w_{2,2} & \cdots & w_{n_i,2} \\ \vdots & \vdots & & \vdots \\ w_{1,n_h} & w_{2,n_h} & \cdots & w_{n_i,n_h} \end{pmatrix} \quad (2)$$

隐藏层的输入信号  $I_h$  为输入层信号  $I$  经过权重矩阵变换的结果：

$$I_h = \begin{pmatrix} w_{1,1} & w_{2,1} & \cdots & w_{n_i,1} \\ w_{1,2} & w_{2,2} & \cdots & w_{n_i,2} \\ \vdots & \vdots & & \vdots \\ w_{1,n_h} & w_{2,n_h} & \cdots & w_{n_i,n_h} \end{pmatrix} \begin{pmatrix} I_1 \\ I_2 \\ \vdots \\ I_{n_i} \end{pmatrix} = W_{i-h} \cdot I \quad (3)$$

接收信号后，神经元不会立即产生反应，而是会抑制输入，直到输入增强到足以触发输出。这是因为神经元不希望传递微小的噪声信号，而只传递有意识的显著信号。为此，在神经网络的每个节点上应用激活函数，即得到下一层的输出信号：

$$O_h = \text{sigmoid}(I_h) \quad (4)$$

其中激活函数的定义为：

$$\text{sigmoid}(x) = 1/(1+e^{-x}) \quad (5)$$

同理，隐藏层与输出层之间的权重矩阵为：

$$W_{h-o} = \begin{pmatrix} w_{1,1} & w_{2,1} & \cdots & w_{n_h,1} \\ w_{1,2} & w_{2,2} & \cdots & w_{n_h,2} \\ \vdots & \vdots & & \vdots \\ w_{1,n_o} & w_{2,n_o} & \cdots & w_{n_h,n_o} \end{pmatrix} \quad (6)$$

输出层的输入信号  $I_o$  为隐藏层输出信号  $O_h$  经过权重矩阵变换后的结果：

$$I_o = W_{h-o} \cdot O_h \quad (7)$$

在输出层的每个节点上应用激活函数，即得到输出层的输出信号：

$$O_o = \text{sigmoid}(I_o) \quad (8)$$

### 1.4 输出误差的反馈

对于训练数据来说，每一个样本的输入层数据  $I$  都有一个期望的输出值  $T$ ：

$$T = \begin{pmatrix} t_1 \\ t_2 \\ \vdots \\ t_{n_o} \end{pmatrix} \quad (9)$$

期望值  $T$  与  $O_o$  之差称为误差矩阵：

$$E = T - O_o = \begin{pmatrix} t_1 - o_1 \\ t_2 - o_2 \\ \vdots \\ t_{n_o} - o_{n_o} \end{pmatrix} = \begin{pmatrix} e_1 \\ e_2 \\ \vdots \\ e_{n_o} \end{pmatrix} \quad (10)$$

#### 1.4.1 输出误差向隐藏层的反馈

根据误差按权重分配的思想， $e_1$  分配到  $w_{1,1}$ ， $w_{2,1}$ ， $w_{3,1}$ ， $\cdots$ ， $w_{n_h,1}$  链路的比率分别为：

$$\left. \begin{aligned} &w_{1,1} / (w_{1,1} + w_{2,1} + w_{3,1} + \cdots + w_{n_h,1}) \\ &w_{2,1} / (w_{1,1} + w_{2,1} + w_{3,1} + \cdots + w_{n_h,1}) \\ &\vdots \\ &w_{n_h,1} / (w_{1,1} + w_{2,1} + w_{3,1} + \cdots + w_{n_h,1}) \end{aligned} \right\}$$

同理， $e_2$  分配到  $w_{1,2}$ ， $w_{2,2}$ ， $w_{3,2}$ ， $\cdots$ ， $w_{n_h,2}$  链路的比率分别为：

$$\left. \begin{aligned} &w_{1,2}/(w_{1,2} + w_{2,2} + w_{3,2} + \dots + w_{n_h,2}) \\ &w_{2,2}/(w_{1,2} + w_{2,2} + w_{3,2} + \dots + w_{n_h,2}) \\ &w_{3,2}/(w_{1,2} + w_{2,2} + w_{3,2} + \dots + w_{n_h,2}) \\ &\quad \vdots \\ &w_{n_h,2}/(w_{1,2} + w_{2,2} + w_{3,2} + \dots + w_{n_h,2}) \end{aligned} \right\} \circ$$

余下以此类推……。

### 1.4.2 反向传播误差到更多层中

根据误差反向传递的思想，隐藏层节点 1 链接着输出层的节点 1, 2, 3, …,  $n_o$ ，后者的误差都可以通过链路  $w_{1,1}$ ,  $w_{1,2}$ ,  $w_{1,3}$ , …,  $w_{1,n_o}$  反向传递到隐藏层节点 1，因此该节点的误差为：

$$\begin{aligned} e_{h,1} &= w_{1,1}/(w_{1,1} + w_{2,1} + w_{3,1} + \dots + w_{n_h,1}) \cdot \\ &e_{o,1} + w_{1,2}/(w_{1,2} + w_{2,2} + w_{3,2} + \dots + w_{n_h,2}) \cdot e_{o,2} + \dots + \\ &w_{1,n_o}/(w_{1,n_o} + w_{2,n_o} + w_{3,n_o} + \dots + w_{n_h,n_o}) \cdot e_{o,n_o} \circ \end{aligned}$$

$$\mathbf{E}_h = \begin{pmatrix} w_{1,1}/(w_{1,1} + w_{2,1} + \dots + w_{n_h,1}) & w_{1,2}/(w_{1,2} + w_{2,2} + \dots + w_{n_h,2}) & \dots & w_{1,n_o}/(w_{1,n_o} + w_{2,n_o} + \dots + w_{n_h,n_o}) \\ w_{2,1}/(w_{1,1} + w_{2,1} + \dots + w_{n_h,1}) & w_{2,2}/(w_{1,2} + w_{2,2} + \dots + w_{n_h,2}) & \dots & w_{2,n_o}/(w_{1,n_o} + w_{2,n_o} + \dots + w_{n_h,n_o}) \\ \vdots & \vdots & & \vdots \\ w_{n_h,1}/(w_{1,1} + w_{2,1} + \dots + w_{n_h,1}) & w_{n_h,2}/(w_{1,2} + w_{2,2} + \dots + w_{n_h,2}) & \dots & w_{n_h,n_o}/(w_{1,n_o} + w_{2,n_o} + \dots + w_{n_h,n_o}) \end{pmatrix} \cdot \begin{pmatrix} e_1 \\ e_2 \\ \vdots \\ e_{n_o} \end{pmatrix} \circ$$

上式中各个分母只是一些归一化因子，其大小不影响误差的分配，因此将所有的分母都变成 1：

$$\mathbf{E}_h = \begin{pmatrix} w_{1,1} & w_{1,2} & \dots & w_{1,n_o} \\ w_{2,1} & w_{2,2} & \dots & w_{2,n_o} \\ \vdots & \vdots & & \vdots \\ w_{n_h,1} & w_{n_h,2} & \dots & w_{n_h,n_o} \end{pmatrix} \cdot \begin{pmatrix} e_1 \\ e_2 \\ \vdots \\ e_{n_o} \end{pmatrix}; \quad (11)$$

$$\mathbf{E}_h = \mathbf{W}_{h_o}^T \cdot \mathbf{E}_o \circ \quad (12)$$

### 1.5 链接权重的更新

先关注隐藏层与输出层之间的链接权重：

$$\frac{\partial E}{\partial w_{j,k}} = \frac{\partial}{\partial w_{j,k}} \sum_{i=1}^{n_o} e_i^2 = \frac{\partial}{\partial w_{j,k}} \sum_{i=1}^{n_o} (t_i - o_i)^2 \circ$$

$w_{j,k}$  只链接到输出层的节点  $k$ ，其偏差只会引起节点  $k$  的误差。因此上述求和只需取第  $k$  项即可：

$$\frac{\partial E}{\partial w_{j,k}} = \frac{\partial}{\partial w_{j,k}} e_k^2 = \frac{\partial}{\partial w_{j,k}} (t_k - o_k)^2 \circ$$

$t_k$  为常数，则上式演化成：

$$\frac{\partial E}{\partial w_{j,k}} = -2(t_k - o_k) \frac{\partial o_k}{\partial w_{j,k}} \circ$$

式中  $o_k$  为节点  $k$  的输出，是隐藏层的各个输出链接到输出层节点  $k$  的和再经过激活函数作用的结果：

同理，反向传递到其余隐藏层节点的误差为：

$$\begin{aligned} e_{h,2} &= w_{2,1}/(w_{1,1} + w_{2,1} + w_{3,1} + \dots + w_{n_h,1}) \cdot \\ &e_{o,1} + w_{2,2}/(w_{1,2} + w_{2,2} + w_{3,2} + \dots + w_{n_h,2}) \cdot e_{o,2} + \dots + \\ &w_{2,n_o}/(w_{1,n_o} + w_{2,n_o} + w_{3,n_o} + \dots + w_{n_h,n_o}) \cdot e_{o,n_o}, \\ &\quad \vdots \\ e_{h,n_h} &= w_{n_h,1}/(w_{1,1} + w_{2,1} + w_{3,1} + \dots + w_{n_h,1}) \cdot e_{o,1} + \\ &w_{n_h,2}/(w_{1,2} + w_{2,2} + w_{3,2} + \dots + w_{n_h,2}) \cdot e_{o,2} + \dots + \\ &w_{n_h,n_o}/(w_{1,n_o} + w_{2,n_o} + w_{3,n_o} + \dots + w_{n_h,n_o}) \cdot e_{o,n_o} \circ \end{aligned}$$

### 1.4.3 使用矩阵乘法进行反向误差传播

可以将输出层误差写成矩阵的形式：

$$\mathbf{E}_o = \begin{pmatrix} e_1 \\ e_2 \\ \vdots \\ e_{n_o} \end{pmatrix}, \text{ 则}$$

$$o_k = \text{sigmoid} \left( \sum_{i=1}^{n_h} w_{i,k} o_i \right) \circ$$

因此：

$$\frac{\partial E}{\partial w_{j,k}} = -2(t_k - o_k) \frac{\partial}{\partial w_{j,k}} \text{sigmoid} \left( \sum_{i=1}^{n_h} w_{i,k} o_i \right);$$

$$\frac{\partial E}{\partial w_{j,k}} = -2(t_k - o_k) \text{sigmoid} \left( \sum_{i=1}^{n_h} w_{i,k} o_i \right) \cdot$$

$$\left[ 1 - \text{sigmoid} \left( \sum_{i=1}^{n_h} w_{i,k} o_i \right) \right] \cdot \frac{\partial}{\partial w_{j,k}} \left( \sum_{i=1}^{n_h} w_{i,k} o_i \right) =$$

$$-2(t_k - o_k) \text{sigmoid} \left( \sum_{i=1}^{n_h} w_{i,k} o_i \right) \cdot$$

$$\left[ 1 - \text{sigmoid} \left( \sum_{i=1}^{n_h} w_{i,k} o_i \right) \right] \cdot o_j = -2(t_k - o_k) o_k \cdot (1 - o_k) \cdot o_j \circ$$

上式中前面的常数“2”无关紧要，只考虑误差的斜率，这样就可使用梯度下降法调整链接系数，可以去掉这个常数：

$$\frac{\partial E}{\partial w_{j,k}} = -(t_k - o_k) o_k \cdot (1 - o_k) \cdot o_j \circ \quad (13)$$

有了斜率表达式后，就可用它来更新权重因子：

$$w_{j,k}(\text{new}) = w_{j,k}(\text{old}) - \alpha \cdot \frac{\partial E}{\partial w_{j,k}} \circ \quad (14)$$

其中  $\alpha$  为学习率因子。

## 2 制作神经网络

神经网络应包括以下内容：1) 初始化：设定输入层、隐藏层和输出层及其节点数量；2) 训练：给定训练样本集后，通过学习优化权重因子；3) 查询：给定输入，从输出节点得到答案。

### 2.1 样本数据的准备

将输入值控制在 0.01~0.99 的范围，输入值不能为 0，否则造成学习能力的丧失。例如，有下列一组输入值如表 1 所示，最大数为 255；首先可将左右的数除以 255，得到 0~1.0 范围的一组值，如表 2 所示。

表 1 输入值实例 (0~255)

133	254	221	37	72	248	182	164
187	31	95	233	8	114	58	39

表 2 输入值实例 (0~1.0)

0.522	0.996	0.867	0.145	0.282	0.973	0.714	0.643
0.733	0.122	0.373	0.914	0.031	0.447	0.227	0.153

每个值乘以 0.99，再加上 0.01，得到 0.01~0.99 范围的一组值，如表 3 所示。

表 3 输入值实例 (0.01~0.99)

0.526	0.996	0.868	0.154	0.290	0.973	0.717	0.647
0.736	0.130	0.379	0.915	0.041	0.453	0.235	0.161

激活函数 sigmoid 限制了输出值的范围只能在 (0, 1.0)，但实际上 0 和 1.0 都是不可能达到的，因此将输出值控制在 (0.01, 0.99)。

### 2.2 初始化权重矩阵

禁止将初始权重因子设置为相同的恒定值；禁止将初始权重因子均设置为 0；建议随机采样，采样范围在 ± (每个节点传入链接数平方根的倒数) 之间。例如每个节点有 100 条链接，则采样范围在  $-1/\sqrt{100} \sim 1/\sqrt{100}$  之间。还有一种方法：从均值为 0，标准方差等于 (每个节点传入链接数平方根的倒数) 的正态分布进行采样。

### 2.3 测试网络

使用较小的样本集测试网络逻辑，等测试通过以后再换成完整样本集。

### 2.4 训练网络

使用完整样本集训练网络。通过对已知样本的学习不断改进权重矩阵。

### 2.5 改进神经网络

初创的神经网络往往存在不足，仿真效果不能

令人满意，需要进行改进。

#### 2.5.1 调整学习率

学习率影响梯度下降法的步长，步长过大或过小都是不利的，需要通过尝试取得一个较合理的值。

#### 2.5.2 多个世代

当训练样本集较小时，网络往往得不到充分的训练。一种有效的方法是重复多次训练。训练一次被称为一个世代。具有 10 个世代的训练，意味着使用整个训练样本集运行学习程序 10 次。通过对样本集进行多次训练，可提供更多爬坡下降的机会，有助于在梯度下降过程中进行更彻底的权重更新。

#### 2.5.3 改变网络形状 (网络层数、节点数)

由于神经网络只有一个输入层和一个输出层，因此改变网络层数指的是改变隐藏层的层数。同样，输入层只需引入输入信号，输出层只需送出答案，气节点数是确定的，只有隐藏层的节点数是不定的，可人为改变。

如果隐藏层节点太少，不可能有足够的空间让网络学习任何知识，并将所有输入转换为正确的输出。另一方面，如果隐藏层节点太多，由于有太多的路径供学习选择；因此，训练网络的工作量会大大增加，甚至难以完成训练网络。

需通过尝试取得一个较合理的隐藏层节点数。

## 3 核素识别

### 3.1 样本数据

样本数据涵盖镅、镅、钚、氡、钋、钴、铯 7 种核素，一共实测了 24 条能谱曲线。这些能谱数据中，既有单一样本的能谱，又有二元或三元核素的复合谱。部分核素的实测能谱如图 2 所示。

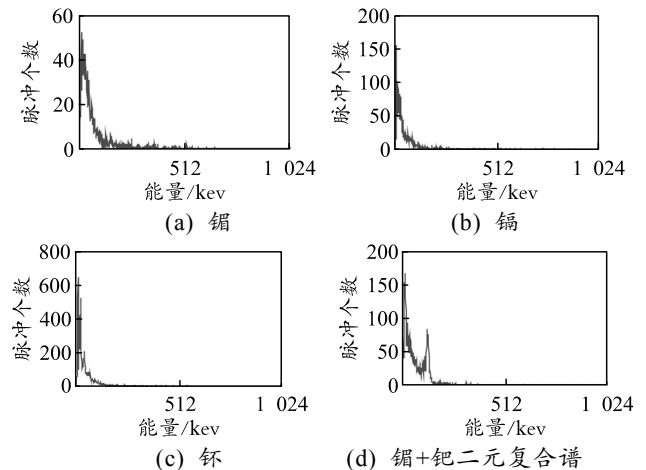


图 2 部分实测能谱示例

### 3.2 网络参数的选取

以下是分析过程中需要重点关注的参数：

#### 1) 输入层节点数。

每幅能谱曲线包含 1 024 道的信息，因此输入层节点数可取为 1 024。经过仔细观察会发现，所有核素的能谱信息都主要集中在低道数区段，而高道数区段上的能谱信号都很小。仿真分析时完全可以忽略高道数区段，这样做的好处是可以减少输入层节点数，减少冗余信息，节省运算资源，提高分析效率。实际操作中只保留前 500 道的信息，而忽略这之后的数据，将输入层节点数定为  $n_i=500$ 。

#### 2) 输出层节点数。

本次分析中一共存在 7 种不同的核素，因此输出层节点数  $n_o=7$ 。输出向量的格式为 

--	--	--	--	--	--	--

，从左向右每个单元格分别代表镅、镅、钷、氡、钷、钴、铯，例如 1000000 表示样本为镅，0100000 表示样本为镅，0110000 表示样本为镅+钷，以此类推。

#### 3) 隐藏层节点数。

通过尝试最终确定隐藏层节点数  $n_h=100$ 。

#### 4) 学习率因子 $\alpha$ 。

通过尝试最终确定学习率因子  $\alpha=0.3$ 。

#### 5) 世代数。

由于核素能谱样本数只有 24 个，数量相对较少，为了获得较好的逼近效果，需要对样本集进行多次训练，本次分析中世代数为 30。

### 3.3 结果与分析

通过对 24 个训练样本多达 30 次的重复训练学习，获得了较为彻底的权重矩阵系数更新。更新后的权重矩阵  $W_{i_h}$ 、 $W_{h_o}$  构成了神经网络预测能力的基石，神经网络对未知样本的预测准确度完全依赖于 2 个权重矩阵。对于未知样本，把它的能谱信号整理成式(1)的列向量形式，然后依次代入式(3)、(4)、(7)、(8)等，即可得到最终的预测结果。用上述核素预测识别模型，对另一组 18 个完全独立的能谱数据进行预测，结果如表 4 所示。

表 4 能谱数据预测结果

编号	期望值	镅	镅	钷	氡	钷	钴	铯
1	镅	0.94	0.02	0.01	0.01	0.02	0.11	0.01
2	镅	0.99	0.08	0.07	0.01	0.13	0.01	0.04
3	镅	0.56	0.02	0.02	0.02	0.01	0.64	0
4	镅	0.91	0.48	0.09	0.01	0.10	0.04	0.01
5	钷	0	0.01	0.01	0.04	0.01	0.99	0.03
6	钷	0.01	0	0.01	0.02	0	0.99	0.03
7	钷	0.09	0.02	0.01	0.03	0	0.86	0.01
8	钷	0.10	0.02	0.01	0.03	0	0.90	0.01
9	钷	0	0.01	0.01	0.02	0	0.99	0.05
10	钷	0.18	0.02	0.01	0.03	0	0.90	0.01
11	铯	0.03	0.01	0	0.02	0.02	0.01	0.98
12	镅	0.02	0.88	0.16	0.04	0.06	0.02	0.06
13	钷	0.02	0.49	0.85	0.02	0.17	0.02	0.01
14	氡	0	0.15	0.02	0.67	0.12	0.13	0.08
15	钷	0.03	0.10	0.04	0.05	0.94	0.03	0.05
16	镅+钷	0.96	0.73	0.07	0.01	0.05	0.03	0.01
17	镅+钷	0.01	0.95	0.98	0.02	0.30	0.06	0.01
18	镅+钷+铯	0.02	0.77	0.96	0.02	0.85	0.01	0.01

从上表的汇总结果可以看出，第 3 号样品的期望值是镅，而预测结果为镅+钷，产生了偏差。跟踪追查发现，产生偏差的主要原因是第 3 号样品的信号偏弱，探测器积分时间设置偏短，信噪比较小。除了第 3 号样品发生意外，其他未知试样的预测结果都正确，整体预测准确性达到 94%。

## 4 结束语

核素识别是核应急和环境监测的前提和基础。笔者利用神经网络优良的自学习能力，实现放射性

核素的准确在线检测和识别，该方法具有广泛的应用前景。

### 参考文献：

- [1] ABBAS M I, ELSAFI M, GOUDA M M, et al. NaI cubic detector full-energy peak efficiency, including coincidence and self-absorption corrections for rectangular sources using analytical method[J]. Journal of Radioanalytical & Nuclear Chemistry, 2021, 327(1): 251-258.
- [2] EI-GAMMAL W, EI-KOURGHLY K M, EI-TAHAWY M S, et al. A hybrid analytical-numerical method for full

energy peak efficiency calibration of a NaI detector[J]. Nuclear Instruments & Methods in Physics Research Section A, 2020, 976(2-3): 164181.

[3] 袁观俊, 魏涛, 郭兰英.  $\gamma$  射线探测器在宽能区光峰效率精密刻度进展[J]. 原子能科学技术, 2003, 37(4): 302-305.

[4] 李必红, 陆士立, 韩绍阳, 等. 核探测中的车载  $\gamma$  能谱技术[J]. 原子能科学技术, 2012, 46(S1): 560-564.

[5] 李传伟, 廖琪梅, 李安宗, 等. 自然伽马能谱解谱方法研究[J]. 核电子学与探测技术, 2008, 28(4): 796-800.

[6] 吴茂良, 樊程芳, 甘绍斌, 等. 建筑材料中天然放射性核素的分析[J]. 辐射防护, 1985(5): 396-399.

[7] 郭颖文. 自然伽马能谱数据解谱方法的研究[J]. 国外测井技术, 2008, 23(6): 49-51.

[8] 侯胜利, 樊卫花. 室内多道  $\gamma$  射线能谱仪(NaI(Tl))谱线分析[J]. 同位素, 2005, 18(S1): 63-66.

[9] PANCHAL I, SAWHNEY I K, SHARMA A K, et al. Classification of healthy and mastitis Murrah buffaloes by application of neural network models using yield and milk quality parameters[J]. Computers & Electronics in Agriculture, 2016, 127: 242-248.

[10] SINGH A K, KUMAR A K, SINGH B, et al. Multiple watermarking technique for securing online social network contents using Back Propagation Neural Network[J]. Future Generation Computer Systems, 2018, 86: 926-939.

[11] 葛峰, 韩建立, 高松. 基于 BAS-BP 神经网络的多应力加速寿命试验预测方法[J]. 兵工自动化, 2020, 39(6): 5-9.

[12] 柴志君, 欧阳中辉, 岳炯. 一种改进的灰色 BP 神经网络预测模型[J]. 兵工自动化, 2020, 39(10): 84-87.

[13] 许杰淋, 何川, 周丽娟, 等. 基于 BP 神经网络的转筒式称量系统的称量效率预测[J]. 兵工自动化, 2020, 39(2): 63-65.

\*\*\*\*\*

(上接第 84 页)

[3] MAKHOV M N, GOGULYS M F. Acceleration ability and heat of explosive decomposition of aluminized explosives[J]. Combustion, Explosion and Shock Waves, 2004, 40(4): 176-183.

[4] 李向东, 钱建平, 曹兵, 等. 弹药概论[M]. 北京: 国防工业出版社, 2004: 20-23.

[5] 黄辉, 黄亨建, 黄勇, 等. 以 RDX 为基的含铝炸药中铝粉粒度和氧化剂形态对加速金属能力的影响[J]. 爆炸与冲击, 2006, 26(1): 7-11.

[6] 韩勇, 黄辉, 黄毅民, 等. 不同直径含铝炸药的做功能力[J]. 火炸药学报, 2008, 31(6): 5-7.

[7] 王儒策, 赵国志, 杨绍卿. 弹药工程[M]. 北京: 北京理工大学出版社, 2002: 33-36.

[8] 王凤英, 刘天生. 毁伤理论与技术[M]. 北京: 北京理工大学出版社, 2009: 40-42.

[9] 王新颖, 王树山, 徐豫新, 等. 杀爆战斗部炸药毁伤能量转换研究[J]. 兵工学报, 2014, 35(S2): 184-187.

[10] 陈朗, 龙新平, 冯长根, 等. 含铝炸药爆轰[M]. 北京: 国防工业出版社, 2004: 51-53.

[11] 隋树元, 王树山. 终点效应学[M]. 北京: 国防工业出版社, 2000: 26-29.

[12] GURNEY G W. The initial velocities of fragments from bombs, shells and grenades[R]. Aberdeen: Ballistics

Research Laboratories, 1943.

[13] 黄菊, 王伯良, 仲倩, 等. 温压炸药能量输出结构的初步研究[J]. 爆炸与冲击, 2012, 32(2): 164-168.

[14] 欧育湘. 炸药学[M]. 北京: 北京理工大学出版社, 2006: 38-42.

[15] 北京工业学院八系《爆炸及其作用》编写组. 爆炸及其作用下册—爆炸对目标的作用和穿甲作用[M]. 北京: 国防工业出版社, 1979: 19-24.

[16] 陈醇, 李伟兵, 王晓鸣, 等. 高能炸药驱动下弹体膨胀破碎过程试验研究[J]. 工程力学, 2015, 32(10): 203-208.

[17] 彭泓铮, 涂兴文, 黄开书, 等. 铝金属放热对破片加载能力影响试验研究[J]. 兵工自动化, 2020, 39(3): 77-81.

[18] 沈飞, 王辉, 袁建飞, 等. 炸药格尼系数的一种简易估算法[J]. 火炸药学报, 2013, 36(6): 36-38.

[19] 陈科全, 路中华, 陈翔, 等. 奥克托今(HMX)基塑料粘结炸药(PBX)驱动不同金属圆筒试验及数值模拟[J]. 科学技术与工程, 2019, 19(8): 94-98.

[20] JOHANSSON C H, PERSSON P. Density and pressure in the Chapman Jouguet Plane as functions of initial density of explosive[J]. Nature, 1966, 212: 1230-1231.

[21] 辛春亮, 徐更光, 刘科科, 等. 含铝炸药与理想炸药能量输出结构的数值模拟[J]. 火炸药学报, 2007, 30(4): 6-9.