

# 基于云模型和矢量神经网络的辐射源识别方法

刘海军, 柳 征, 姜文利, 周一宇

(国防科技大学电子科学与工程学院, 湖南长沙 410073)

**摘 要:** 矢量神经网络在训练阶段既不能处理语义信息, 也没有考虑训练样本本身的可靠性, 因而造成辐射源不能正确识别的问题, 为此提出了一种基于云模型和矢量神经网络的识别算法. 该算法利用云模型来实现定性概念到定量区间值的转换, 并利用改进后的矢量神经网络实现区间类型的矢量输入到区间类型型号输出的非线性映射. 仿真实验表明, 本文方法不仅能处理语义类型的输入矢量, 而且能够处理数字类型的输入矢量, 并且在测量误差环境中具有较高的识别率.

**关键词:** 雷达; 辐射源识别; 云模型; 矢量神经网络; 区间值; 识别率

**中图分类号:** TN95      **文献标识码:** A      **文章编号:** 0372-2112 (2010) 12-2797-08

## Approach Based on Cloud Model and Vector Neural Network for Emitter Identification

LIU Hai-jun, LIU Zheng, JIANG Wen-li, ZHOU Yi-yu

(College of Electronic Science and Engineering, National University of Defense Technology, Changsha, Hunan 410073, China)

**Abstract:** To deal with the problem of emitter identification caused by the vector neural network (VNN), which is incapable of processing the linguistic information and considering the reliability of the training samples in training phases, this paper proposes a new identification method based on cloud model and vector neural network (CMVNN). The new method, which utilizes the cloud model to realize the transformation from qualitative concepts to their quantitative interval expressions, can make use of the improved vector neural network to come true the nonlinear mapping between the interval-value input data and the interval-value output emitter types. A number of simulations are presented to demonstrate the performance of the CMVNN algorithm, including processing 3-type emitter identification problem. Simulation results show that the CMVNN algorithm not only processes the linguistic and numerical input data, but also has higher identification rate in environment with measure errors.

**Key words:** radar; emitter identification; cloud model; vector neural network; interval value; identification rate

## 1 引言

天基电子侦察系统侦察范围广、速度快, 且不受地理、国界限制, 已成为获取军事情报信息的主要来源. 在整个侦察系统中, 辐射源识别模块是其中的重要组成部分, 它能够通过侦测敌方雷达、通信等系统的电磁辐射来获取其系统的性能、位置及部署情况, 并在有关情报的支持下, 判定辐射源型号, 为进一步判定与辐射源相关的武器系统和目标提供决策保障. 因此正确有效的进行辐射源识别, 具有非常重要的军事意义<sup>[1]</sup>.

辐射源识别过程可以认为是一种特殊的信息处理过程. 当进行信息处理时, 就要考虑到有两种可用的信息: 一种为来自人类专家的语义信息; 另一种为来自测量设备的数字信息, 其中数字信息又分为标量类型和区

间类型. 本文的重点是研究能够处理这两种信息的分类识别算法. 现有的很多分类识别方法, 包括基于贝叶斯理论的方法<sup>[2]</sup>、基于模糊模式识别的方法<sup>[3]</sup>、基于最近邻的方法<sup>[4]</sup>、基于粗糙集理论的方法<sup>[5]</sup>、基于证据理论的方法<sup>[6]</sup>、基于人工神经网络的方法<sup>[7]</sup>等等, 在辐射源识别中都有比较成功的应用. 但这些方法一般都针对测量参数为标量形式的测量值进行处理, 在一定程度上解决了由于参数测量误差所引起的辐射源识别问题. 对于误差的另一种情形, 即测量参数为区间类型模糊值的情况却讨论较少. 文献[8]提出了一种基于模糊 IF-Then 规则的神经网络算法, 能够实现模糊输入到模糊输出的非线性映射. 文献[9]在文献[8]的基础上, 对代价函数进行修正, 给出了矢量神经网络 VNN (Vector Neural Network) 的概念, 并提出了一种新类型的矢量神经网络

NVTBP(New Vector-Type Backpropagation)算法用于辐射源识别,取得了较好的效果.但该方法在训练时没有考虑到训练样本本身的可靠性,并且只能处理定量数据,而不能处理如“大”,“小”,“多”,“少”等的定性数据,容易造成分类识别的精度变差.如何利用智能方法对这些定性数据进行处理显得尤为重要,而云模型为此提供了很好的解决途径.云模型是李德毅院士提出的一种定性定量不确定性转换模型,它将模糊集理论中的模糊性和概率理论中的随机性有机地结合起来,通过期望  $Ex$  (Expected value)、熵  $En$  (Entropy)、超熵  $He$  (Hyper entropy) 3 个数字特征来整体表征一个概念<sup>[10-13]</sup>,并在性能评估等领域取得了很好的应用<sup>[14-16]</sup>.因此本文将引入并加以改进以实现定性概念值到定量区间值的转换,并利用改进后的矢量神经网络实现区间类型的矢量输入到区间类型型号输出的非线性映射.

针对上述情况,本文重点研究如何利用语义信息和训练样本本身的可靠性来训练矢量神经网络,提出了一种基于云模型和矢量神经网络的 CMVNN(Cloud Model and Vector Neural Network)识别算法.

## 2 问题描述

本文主要讨论雷达辐射源的型号识别问题.所谓辐射源型号识别,就是将侦察到的辐射源特征参数与雷达模板库中的模板雷达的特征参数进行匹配,从而得到该辐射源型号的过程,从神经网络分类的角度来看,其目的是实现从参数特征空间到辐射源型号空间的非线性映射.所用到的特征参数主要有:载频  $RF$  (radio frequency)、脉宽  $PW$  (pulse width)、脉冲重复间隔  $PRI$  (pulse repeat interval)、脉内调制  $MOP$  (modulation on the radar pulse) 等等.

当前辐射源识别面临的问题主要有两个方面:一方面由于电磁环境复杂多变、各种干扰的存在以及侦察设备本身的测量误差使得获得的辐射源特征参数跟真值相比具有一定的偏差,从而造成辐射源特征参数测量值的不确定性;另一方面由于模板雷达通常是通过各种渠道获得,因此其特征参数也存在不准确、不完备的情形,这就造成了模板库雷达特征参数的不确定性.这里所说的不确定性在一般情况下可以用区间值来表示,如对于频率捷变雷达、重频抖动雷达等的侦察测量,在实际中往往不能给出精确的测量值,通常用区间值来表示,即,

$$S = [s_1, s_2, s_3] = [[s_1^L, s_1^U], [s_2^L, s_2^U], [s_3^L, s_3^U]] \quad (1)$$

式中  $S$  为测量得到的区间矢量,  $s_i$  ( $i = 1, 2, 3$ ) 表示辐射源相应特征参数(如载频  $RF$ )的测量区间值,  $L, U$  分别表示区间的下限和上限.

由式(1)可知,研究针对区间值的分类算法在辐射

源识别中具有很重要的意义.文献[9]提出了一种新型矢量神经网络(NVTBP)算法,不仅能处理区间类型的输入矢量,而且能够处理标量类型的输入矢量,在辐射源识别中取得了较好的效果.但是该方法存在以下两个缺点:

(1)只能处理定量数据,而不能处理如“大”,“小”,“多”,“少”等的定性数据;

(2)在训练时没有考虑到训练样本本身的可靠性.虽然文献[8]对该点有所涉及,但文中没有给出样本可靠系数的计算方法并将其应用到网络的训练过程中.

针对上述缺点,本文提出了一种基于云模型和改进型矢量神经网络的 CMVNN 识别算法. CMVNN 算法的示意图如图 1 所示.

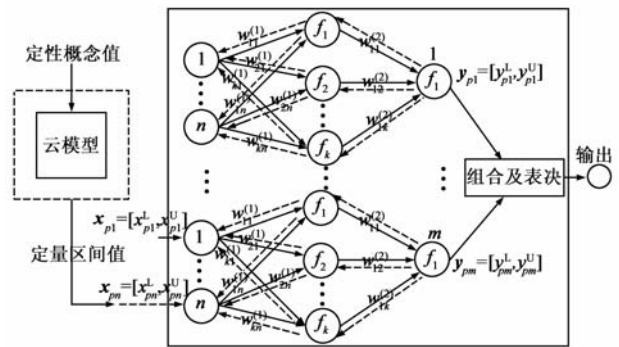


图1 CMVNN算法示意图

从图 1 可以看出,CMVNN 算法利用云模型来实现定性概念值到定量区间值的转换,并利用改进后的矢量神经网络实现区间类型的矢量输入到区间类型型号输出的非线性映射.图 1 中改进型矢量神经网络结构由  $m$  个多输入单输出的矢量神经网络 VNN 组合而成,每个 VNN 的网络结构为  $n - k - 1$ ,即含有  $n$  个输入节点,  $k$  个隐含节点,以及一个输出节点.在每个 VNN 网络中都有两种传播箭头,其中实线箭头表示前向传播,虚线箭头表示反向传播,网络的隐含层和输出层的神经元中的标志  $f$  表示神经元的激活函数,通常用 sigmoid 函数来表示.上图中改进型矢量神经网络的实际输出  $y_{output}$  为:

$$y_{output} = \max\{y_{pq}^U, \quad q = 1, 2, \dots, m\} \quad (2)$$

## 3 CMVNN 算法

CMVNN 算法由两部分组成,一部分为基于云模型的定性定量转换算法,另一部分为基于改进型矢量神经网络的分类算法.

### 3.1 基于云模型的定性定量转换算法

云模型是一种定性定量不确定性转换模型,通过期望  $Ex$ 、熵  $En$ 、超熵  $He$  三个数字特征来整体表征一个定性概念<sup>[10-16]</sup>.本节针对辐射源特征参数具有不同数据类型(连续型和离散型)的特点,提出了一种利用云

模型实现定性概念值到带有一定置信度定量区间值的转换算法,主要实现以下两种功能:

(1)实现连续型特征参数的定性概念值到一定置信度定量区间值的转换,定性概念值如“载频  $RF$  很大”等等;

(2)实现离散型特征参数的定性概念值到一定置信度定量区间值的转换,定性概念值如脉内调制 MOP “二相编码调制效果很好”等等;

本文主要利用  $Y$  条件正向云发生器来实现定性定量转换.由云的数字特征产生云滴,即实现从定性到定量的转换,称为正向云发生器(如图 2(a)).云可以根据不同的条件来生成,在给定论域中特定的数值  $y$  (即确定度  $\mu$ ) 的条件下的云发生器称为  $Y$  条件正向云发生器(如图 2(b)).




图2 云发生器示意图

正向云的生成算法:

(1)生成以  $En$  为期望值,  $He^2$  为方差的一个正态随机数  $En'_i = NORM(En, He^2)$ ;

(2)生成以  $Ex$  为期望值,  $En'^2_i$  为方差的一个正态随机数  $x_i = NORM(Ex, En'^2_i)$ ;

(3)计算确定度,生成云滴:

$$\mu_i = e^{-\frac{(x_i - Ex)^2}{2(En'_i)^2}} \quad (3)$$

则  $(x_i, \mu_i)$  即为生成的云滴

$Y$  条件正向云生成算法:

(1)生成以  $En$  为期望值,  $He^2$  为方差的一个正态随机数  $En'_i = NORM(En, He^2)$ ;

(2)代入  $\mu_i = \mu_0$ , 计算式(4), 生成云滴:

$$x_i = Ex \pm \sqrt{-2\ln(\mu_0) En'^2_i} \quad (4)$$

则  $(x_i, \mu_0)$  即为生成的云滴;

需要说明的是,云模型可用期望值为约束条件的中值,主要作用区域为双边约束区域  $[C_{min}, C_{max}]$  的云来近似建模(即正态云建模,复杂情况可以采用组合云建模),  $Ex, En, He$  的计算公式如下所示:

$$\begin{cases} Ex = (C_{max} + C_{min})/2 \\ En = (C_{max} - C_{min})/6 \\ He = k \end{cases} \quad (5)$$

式中  $k$  为常数,可根据具体指标的模糊性和随机性具体调整.

基于正向云及  $Y$  条件正向云生成算法,实现上述两种类型特征参数的定性概念值到一定置信度的定量

区间值转换的具体步骤为:

(1)连续型特征参数的定性概念值到一定置信度定量区间值的转换.以“载频  $RF$  很大”为例,转换模型如图 3 所示.




图3 连续型特征参数的转换模型

图 3 为连续型特征参数的定性定量转换模型,对应定性概念“载频  $RF$  很大”,云模型的三个数字特征分别为:  $Ex$  为 9GHz,  $En$  为 0.333GHz,  $He$  为 0.01,云滴个数  $N$  为 1000.图中符号  $\lambda$  代表该载频特征的可靠系数,可以看出对于一个给定的特征可靠系数  $\lambda = 0.6$ ,可得定量区间值  $[8.67, 9.33]$ ,置信度为 0.6.需要说明的是,图 3 中的连续型特征参数的定性定量转换模型是以正态云建模为前提的,对于特征参数分布复杂的情况,可以基于组合云建模来实现.

(2)离散型特征参数的定性概念值到一定置信度定量区间值的转换.以脉内调制 MOP 为例,为了更好的描述脉内调制类型及调制效果的好坏,我们对不同的调制类型赋予不同的云模型.假设调制类型有五种:常规调制、二相编码、四相编码、线形调频和双线形调频,利用  $[0, 1]$  之间 5 个等间隔的双边约束区域  $[C_{min}^i, C_{max}^i]$  ( $i = 1, 2, \dots, 5$ ) 对调制类型进行正态云建模,转换模型示意图如图 4 所示.需要说明的是,此处 5 种调制类型的定性定量转换模型是以正态云建模为前提的,对于特征参数分布复杂的情况,可以采用组合云建模的方式,并且这 5 种调制类型的排列顺序不会影响到后续的处理结果,在实际中对这 5 种类型的调制方式进行建模时也可以采用不等间隔的方式.

从图 4 中可以看出,该转换模型有 5 个具有不同数字特征的云模型组成,图中符号  $\lambda$  表示调制效果的程




图4 离散型特征参数的转换模型

度(即特征可靠系数).可以看出对于一个给定的特征可靠系数  $\lambda = 0.6$ , 每种调制方式对应的定量区间值是不同的. 利用式(5)计算上述 5 种调制方式对应的云模型的数字特征, 具体参数如表 1 所示.

表 1 云模型数字特征

| 调制方式  | 期望( $E_x$ ) | 熵( $E_n$ ) | 超熵( $E_h$ ) |
|-------|-------------|------------|-------------|
| 双线形调频 | 0.9         | 0.034      | 0.001       |
| 线形调频  | 0.7         | 0.034      | 0.001       |
| 四相编码  | 0.5         | 0.034      | 0.001       |
| 二相编码  | 0.3         | 0.034      | 0.001       |
| 常规调制  | 0.1         | 0.034      | 0.001       |

### 3.2 基于改进型矢量神经网络的分类算法

本节针对矢量神经网络 NVTBP 在训练时没有考虑到训练样本本身的可靠性而造成分类识别精度低的缺点<sup>[9]</sup>, 提出了一种样本可靠系数的计算方法并将其体现到网络的训练过程中. 该方法充分考虑了辐射源各个不同特征参数的可靠系数及其在总的可靠系数中所占的比重, 具体方法如下:

设某一训练样本对为  $(\mathbf{x}_p, \mathbf{d}_p, \lambda_p)$ ,  $p = 1, 2, \dots, N$ , 其中  $\mathbf{x}_p$  为区间类型的输入矢量, 表示第  $p$  个训练样本, 且  $\mathbf{x}_p = [\mathbf{x}_{p1}, \mathbf{x}_{p2}, \dots, \mathbf{x}_{pm}]$ ,  $n$  为输入特征的维数,  $\mathbf{x}_{pi}$  表示第  $i$  个输入特征, 为区间类型值, 即  $\mathbf{x}_{pi} = [\mathbf{x}_{pi}^L, \mathbf{x}_{pi}^U]$ ;  $\mathbf{d}_p$  为与第  $p$  个训练样本相对应的改进型矢量神经网络的期望输出,  $\mathbf{d}_p = [d_{p1}, d_{p2}, \dots, d_{pm}]$ , 且  $d_{pi} \in \{0, 1\}$ ,  $m$  为改进型网络结构中组合的矢量神经网络 VNN 的个数;  $\lambda_p$  为训练样本的可靠系数, 表示训练样本  $\mathbf{x}_p$  属于  $\mathbf{d}_p$  所代表类别的程度,  $\lambda_p \in [0, 1]$ . 对于训练样本  $\mathbf{x}_p$  的每一个输入特征  $\mathbf{x}_{pi}$ , 都存在一个与之相对应的特征可靠系数  $\lambda_{pi}$  ( $\lambda_{pi}$  可由专家指定或通过隶属度函数数值计算得到), 若该特征可靠系数在总的样本可靠系数中所占的权重为  $\omega_{pi}$ , 则样本的可靠系数  $\lambda_p$  可通过下式来计算:

$$\lambda_p = \omega_{p1}\lambda_{p1} + \omega_{p2}\lambda_{p2} + \dots + \omega_{pm}\lambda_{pm} = \sum_{i=1}^n \omega_{pi}\lambda_{pi} \quad (6)$$

其中, 
$$\sum_{i=1}^n \omega_{pi} = 1 \quad (7)$$

从式(6)可以看出, 样本可靠系数  $\lambda_p$  的计算充分考虑了每个特征参数测量区间值的可靠性及其在总的样本可靠系数中所占的比重.

利用样本的可靠系数  $\lambda_p$  对网络的输出误差进行修正可以得到修正后的输出误差. 假设改进型矢量神经网络由  $m$  个多输入单输出的矢量神经网络 VNN 组合而成, 每个 VNN 的网络结构为  $n - k - 1$ . 与训练样本  $\mathbf{x}_p$  对应的第  $q$  ( $q = 1, 2, \dots, m$ ) 个矢量神经网络的输出误差为  $E_{pq}$ , 则修正后的输出误差为  $E'_{pq}$ :

$$E'_{pq} = \lambda_p \times E_{pq} \quad (8)$$

对于输出误差  $E_{pq}$  的计算, 可以引入文献[9]中的公式, 即

$$E_{pq} = \begin{cases} -d_{pq} \ln y_{pq}^L - (1 - d_{pq}) \ln(1 - y_{pq}^L), & \text{if } d_{pq} = 1 \\ -d_{pq} \ln y_{pq}^U - (1 - d_{pq}) \ln(1 - y_{pq}^U), & \text{if } d_{pq} = 0 \end{cases} \quad (9)$$

利用式(8)对输出误差  $E_{pq}$  进行修正可得修正后的输出误差  $E'_{pq}$ , 此时网络总的输出误差为:

$$E_p = \sum_{q=1}^m E'_{pq} = \lambda_p \sum_{q=1}^m E_{pq} \quad (10)$$

样本可靠系数  $\lambda_p$  在改进型矢量神经网络训练中所起的作用主要体现在网络的后向传播算法上. 后向传播的主要目的是根据修正后的输出误差  $E'_{pq}$  计算权值  $w_{ji}^{(1)}(t)$  和  $w_{lj}^{(2)}(t)$  ( $w_{ji}^{(1)}$  为网络输入层与隐含层的权值,  $w_{lj}^{(2)}$  为网络隐含层与输出层的权值) 的修正量, 经过不断迭代得到最优权值矩阵, 从而实现输入区间特征矢量与输出辐射源型号的非线性映射. 权值修正公式为:

$$\begin{aligned} \Delta w_{ji}^{(1)}(t) &= -\eta \left( \frac{\partial E'_{pq}}{\partial w_{ji}^{(1)}(t)} \right) + \alpha \Delta w_{ji}^{(1)}(t-1) \\ &= -\lambda_p \eta \left( \frac{\partial E_{pq}}{\partial w_{ji}^{(1)}(t)} \right) + \alpha \Delta w_{ji}^{(1)}(t-1) \end{aligned} \quad (11)$$

$$\begin{aligned} \Delta w_{lj}^{(2)}(t) &= -\eta \left( \frac{\partial E'_{pq}}{\partial w_{lj}^{(2)}(t)} \right) + \alpha \Delta w_{lj}^{(2)}(t-1) \\ &= -\lambda_p \eta \left( \frac{\partial E_{pq}}{\partial w_{lj}^{(2)}(t)} \right) + \alpha \Delta w_{lj}^{(2)}(t-1) \end{aligned} \quad (12)$$

在上述公式中  $\Delta w_{ji}^{(1)}(t)$  表示对权值  $w_{ji}^{(1)}(t)$  当前修正的结果,  $\Delta w_{ji}^{(1)}(t-1)$  表示对  $w_{ji}^{(1)}(t)$  上次的修正结果;  $\Delta w_{lj}^{(2)}(t)$  表示对权值  $w_{lj}^{(2)}(t)$  当前修正的结果,  $\Delta w_{lj}^{(2)}(t-1)$  表示对  $w_{lj}^{(2)}(t)$  上次的修正结果,  $t$  表示训练迭代的次数,  $\eta$  为训练步长,  $\alpha$  为惯性项系数. 通过对式(11)、(12)不断迭代可以得到最优权值矩阵, 从而完成网络的训练过程.

## 4 仿真结果

本节利用 3 类辐射源识别问题来验证 CMVNN 算法对辐射源的识别性能及对测量误差的适应能力. 设计了 3 个实验, 前两个实验为仿真实验, 第一个实验用来验证 CMVNN 算法对连续型特征参数定性概念值的适应能力, 并与 NVTBP 算法进行了比较; 第二个仿真实验用来验证 CMVNN 算法对离散型特征参数定性概念值的适应能力, 同样与 NVTBP 算法进行了比较, 两个实验均采用不同测量误差环境的测试样本进行测试. 第三个实验为实测数据实验, 将 CMVNN 算法与常用的模糊匹配法进行了比较, 验证了算法的有效性. 为了保证网络训练的质量, 无论是 CMVNN 算法还是 NVTBP 算法均采用 10 折交叉验证的方式来获取网络的结构和参

数,即将所有的训练样本分成 10 个相等的子集,其中 9 个子集用于训练,另外一个作为测试子集用来估计网络的性能,整个过程需要迭代 10 次,直到所有子集都作为测试子集参与了网络的训练过程。

#### 4.1 连续型特征参数定性概念值的适应能力测试

本实验中,对于 CMVNN 算法和 NVTBP 算法,均采用辐射源样本的载频  $RF$ 、脉冲重复间隔  $PRI$ 、脉宽  $PW$  三个特征参数进行训练和测试.对于该 3 类辐射源识别问题,CMVNN 算法网络由 3 个网络结构为 3-3-1 的矢量神经网络 VNN 组合而成,训练参数为:训练步长  $\eta = 0.02$ ,惯性项系数  $\alpha = 0.9$ ,最大允许输出误差  $E_{\max} = 0.005$ ;NVTBP 算法的网络结构为 3-8-3,即有 3 个输入节点,8 个隐层节点和 3 个输出节点,训练步长  $\eta = 0.02$ ,惯性项系数  $\alpha = 0.7$ ,最大允许输出误差  $E_{\max} = 0.005$ .网络采用区间类型的训练样本进行训练,并分别采用区间和标量类型的测试样本进行测试.在训练阶段,有 120 个训练样本参与训练,对应每个辐射源型号 40 个,部分训练样本如表 2 所示。

表 2 实验 1 的训练样本对

| 辐射源<br>样本 | $RF(\text{GHz})$ |       | $PRI(\mu\text{s})$ |      | $PW(\mu\text{s})$ |      | 可靠<br>系数 | 辐射源<br>型号 |
|-----------|------------------|-------|--------------------|------|-------------------|------|----------|-----------|
|           | 下限               | 上限    | 下限                 | 上限   | 下限                | 上限   |          |           |
| 1         | 8.95             | 9.25  | 8.62               | 9.07 | 2.43              | 2.97 | 0.7      | 1         |
| 2         | 4.5              | 4.7   | 3.06               | 3.64 | 3.31              | 3.89 | 0.75     | 2         |
| 3         | 9.75             | 10.45 | 8.32               | 9.37 | 2.07              | 3.33 | 0.3      | 3         |
| 4         | 4.44             | 4.76  | 2.89               | 3.81 | 3.14              | 4.06 | 0.6      | 2         |
| 5         | 9.95             | 10.25 | 8.62               | 9.07 | 2.43              | 2.97 | 0.7      | 3         |
| 6         | 8.92             | 9.28  | 8.58               | 9.11 | 2.38              | 3.02 | 0.65     | 1         |
| 7         | 4.26             | 4.94  | 2.37               | 4.33 | 2.62              | 4.58 | 0.15     | 2         |
| 8         | 9.78             | 10.42 | 8.35               | 9.34 | 2.12              | 3.29 | 0.35     | 3         |
| 9         | 9.63             | 10.57 | 8.13               | 9.56 | 1.85              | 3.56 | 0.05     | 3         |
| 10        | 很大               |       | 中等                 |      | 较小                |      | 0.95     | 2         |
| 11        | 4.49             | 4.71  | 3.03               | 3.67 | 3.28              | 3.92 | 0.72     | 2         |
| 12        | 9.8              | 10.4  | 8.39               | 9.3  | 2.16              | 3.24 | 0.4      | 3         |
| 13        | 8.7              | 9.5   | 8.24               | 9.45 | 1.98              | 3.42 | 0.2      | 1         |
| 14        | 4.53             | 4.67  | 3.15               | 3.55 | 3.4               | 3.8  | 0.82     | 2         |
| 15        | 8.69             | 9.51  | 8.22               | 9.47 | 1.96              | 3.44 | 0.18     | 1         |

从表 2 可以看出,除了有定量区间数据参与训练外,还有定性概念值,如第 10 个辐射源样本的参数:载频  $RF$  很大,脉冲重复间隔  $PRI$  中等且脉宽  $PW$  较小.这三个定性概念对应的云模型数字特征分别为:载频  $RF$ :  $Ex$  为 9GHz,  $En$  为 0.333GHz,  $He$  为 0.01;脉冲重复间隔  $PRI$ :  $Ex$  为 5us,  $En$  为 0.333us,  $He$  为 0.01;脉宽  $PW$ :  $Ex$  为 3.6us,  $En$  为 0.383us,  $He$  为 0.01.由于 NVTBP 算法不能处理定性概念值,因此具有定性概念值的辐射源样本不参与 NVTBP 算法的训练过程。

在测试阶段,标量类型和区间类型的测试样本各有 120 个,对应每个辐射源型号 40 个.首先利用无误差测试样本进行测试,其中无误差区间类型的测试样本

来自辐射源样本库,与表 2 相似,只是特征参数仅为定量区间值,而不包括定性概念值;无误差标量类型的测试样本也来自辐射源样本库,部分测试样本如表 3 所示。

表 3 标量类型测试样本

| 辐射源<br>样本 | $RF(\text{GHz})$ |       | $PRI(\mu\text{s})$ |      | $PW(\mu\text{s})$ |      | 辐射源<br>型号 |
|-----------|------------------|-------|--------------------|------|-------------------|------|-----------|
|           | 下限               | 上限    | 下限                 | 上限   | 下限                | 上限   |           |
| 1         | 8.96             | 8.96  | 4.96               | 4.96 | 3.55              | 3.55 | 2         |
| 2         | 9.06             | 9.06  | 8.79               | 8.79 | 2.63              | 2.63 | 1         |
| 3         | 9.82             | 9.82  | 8.43               | 8.43 | 2.21              | 2.21 | 3         |
| 4         | 4.58             | 4.58  | 3.29               | 3.29 | 3.54              | 3.54 | 2         |
| 5         | 9.61             | 9.61  | 8.11               | 8.11 | 1.82              | 1.82 | 3         |
| 6         | 8.88             | 8.88  | 8.51               | 8.51 | 2.29              | 2.29 | 1         |
| 7         | 4.54             | 4.54  | 3.18               | 3.18 | 3.43              | 3.43 | 2         |
| 8         | 8.64             | 8.64  | 8.15               | 8.15 | 1.87              | 1.87 | 1         |
| 9         | 10.03            | 10.03 | 8.73               | 8.73 | 2.57              | 2.57 | 3         |
| 10        | 4.52             | 4.52  | 3.12               | 3.12 | 3.37              | 3.37 | 2         |
| 11        | 9.84             | 9.84  | 8.45               | 8.45 | 2.23              | 2.23 | 3         |
| 12        | 8.63             | 8.63  | 8.13               | 8.13 | 1.85              | 1.85 | 1         |
| 13        | 8.93             | 8.93  | 4.93               | 4.93 | 3.52              | 3.52 | 2         |
| 14        | 10.09            | 10.09 | 8.83               | 8.83 | 2.68              | 2.68 | 3         |
| 15        | 8.96             | 8.96  | 8.64               | 8.64 | 2.45              | 2.45 | 1         |

为了验证算法对不同测量误差的适应能力,还需要用具有不同测量误差的样本进行测试,在此引入误差偏离水平 EDL(error deviation level)<sup>[9]</sup>的概念,并将其推广到区间类型测试样本.EDL 定义如下所示:

$$\text{EDL}_i(\%) = \frac{\xi_{pi}}{x_{pi}} \times 100\% \quad (13)$$

上式中  $x_{pi}$  为无误差数据,  $\xi_{pi}$  为随机测量误差.对于标量类型测试样本,若设无误差测试数据为  $\mathbf{x}_p = (x_{p1}, x_{p2}, x_{p3})$ ,  $\xi_p = (\xi_{p1}, \xi_{p2}, \xi_{p3})$  为与之对应的随机测量误差,则加误差后的测试数据变为  $(x_{p1} \pm \xi_{p1}, x_{p2} \pm \xi_{p2}, x_{p3} \pm \xi_{p3})$ ;对于区间类型测试样本,若设无误差测试数据为  $\mathbf{x}_p = (x_{p1}, x_{p2}, x_{p3})$ ,  $\mathbf{x}_{pi} = [x_{pi}^L, x_{pi}^U]$ ,  $\xi_{pi} = [\xi_{pi}^L, \xi_{pi}^U]$  为与  $\mathbf{x}_{pi}$  对应的随机测量误差,则加误差后的测试数据变为  $\mathbf{x}_{pi} = [x_{pi}^L \pm \xi_{pi}^L, x_{pi}^U \pm \xi_{pi}^U]$ .可以利用无误差数据加测量误差得到不同误差等级的测试数据.为了与文献[9]中的 NVTBP 算法作比较,EDL 的取值为(0 ~ 20%),测试结果如表 4 所示。

从表 4 中可以看出,无论对于低 EDL 还是高 EDL 的测试样本,CMVNN 算法具有比 NVTBP 算法更好的识别性能,尤其是对于标量类型的测试样本,当 EDL 值为 0 时,CMVNN 算法比 NVTBP 算法识别率高出约 15%,在 EDL 值为 20% 的情况下,CMVNN 算法的识别率达到 78.20%,比 NVTBP 算法高出约 25%.对于区间类型的测试样本,也能得出类似的结论.两种算法的识别效果对比图如图 5 所示。

图 5 中,(a)为标量类型测试样本的识别效果对比

图, (b)为区间类型测试样本的识别效果对比图. 从图5中可以看出, CMVNN算法比 NVTBP算法具有更好的测量误差适应能力, 随着 EDL 的增加, NVTBP 算法出现了些许波动, 这主要是由于 NVTBP 算法在训练过程中没有利用定性的训练样本数据及训练样本本身的可靠性而引起分类识别的精度变差造成的.

表 4 实验 1 的识别结果

| 误差偏离水平 (%) | 标量类型测试样本    |             | 区间类型测试样本    |             |
|------------|-------------|-------------|-------------|-------------|
|            | NVTBP 算法    | CMVNN 算法    | NVTBP 算法    | CMVNN 算法    |
|            | 总的平均识别率 (%) | 总的平均识别率 (%) | 总的平均识别率 (%) | 总的平均识别率 (%) |
| 20         | 53.29       | 78.20       | 64.68       | 79.28       |
| 18         | 53.35       | 79.16       | 64.73       | 80.68       |
| 16         | 54.20       | 80.96       | 65.24       | 81.66       |
| 14         | 54.74       | 82.48       | 65.65       | 81.94       |
| 12         | 55.54       | 82.89       | 65.68       | 83.33       |
| 10         | 55.85       | 83.18       | 66.66       | 84.16       |
| 8          | 55.85       | 83.48       | 70.45       | 85.15       |
| 6          | 60.63       | 85.69       | 74.13       | 88.64       |
| 4          | 66.60       | 88.48       | 78.48       | 91.61       |
| 2          | 73.23       | 90.45       | 82.68       | 94.38       |
| 0          | 76.24       | 91.78       | 85.43       | 94.40       |

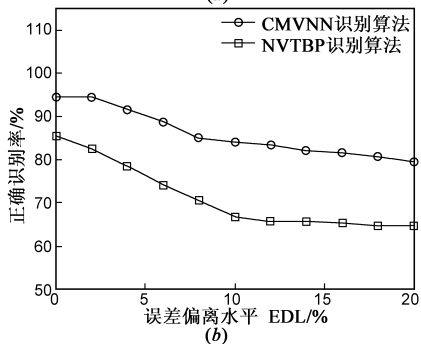



图 5 实验 1 两种算法的识别效果

#### 4.2 离散型特征参数定性概念值的适应能力测试

本实验中, 辐射源特征采用载频  $RF$ 、脉冲重复间隔  $PRI$ 、脉宽  $PW$  和脉内调制  $MOP$  四个参数. 对于该 3 类辐射源识别问题, 由于 NVTBP 算法不能处理定性的脉内调制  $MOP$  信息, 即只能采用载频  $RF$ 、脉冲重复间隔  $PRI$ 、脉宽  $PW$  三个特征参数进行训练和测试, 因此 CMVNN 算法和 NVTBP 算法采用不同的网络结构:

CMVNN 算法由 3 个网络结构为 4-3-1 的矢量神经网络 VNN 组合而成, 训练步长  $\eta = 0.02$ , 惯性项系数  $\alpha = 0.9$ , 最大允许输出误差  $E_{\max} = 0.005$ ; NVTBP 算法的网络结构为 3-8-3, 即有 3 个输入节点, 8 个隐层节点和 3 个输出节点, 训练步长  $\eta = 0.02$ , 惯性项系数  $\alpha = 0.7$ , 最大允许输出误差  $E_{\max} = 0.005$ .

网络采用区间类型的训练样本进行训练, 并分别采用区间和标量类型的测试样本进行测试. 在训练阶段, 有 120 个训练样本参与训练, 对应每个辐射源型号 40 个, 部分训练样本如表 5 所示. 可以看出表 5 中不仅有连续型特征参数的定量区间值, 而且还有离散型特征参数的定性概念值. 在本实验中, 连续型特征参数的可靠系数均为 1, 且各特征参数可靠系数的权值为  $\omega_{pi} = 0.25 (i = 1, 2, 3, 4)$ , 因此可以通过式 (5) 来计算每个训练样本的可靠系数  $\lambda_p$ .

表 5 实验 2 的训练样本对

| 辐射源样本 | $RF$ (GHz) |       | $PRI$ ( $\mu s$ ) |      | $PW$ ( $\mu s$ ) |      | MOP  |        | 可靠系数 | 辐射源型号 |
|-------|------------|-------|-------------------|------|------------------|------|------|--------|------|-------|
|       | 下限         | 上限    | 下限                | 上限   | 下限               | 上限   | 调制类型 | 特征可靠系数 |      |       |
| 1     | 9.74       | 9.86  | 8.75              | 8.94 | 2.59             | 2.81 | 线形调频 | 0.88   | 0.97 | 3     |
| 2     | 8.95       | 9.25  | 8.62              | 9.07 | 2.43             | 2.97 | 二相编码 | 0.72   | 0.93 | 1     |
| 3     | 4.53       | 4.67  | 3.15              | 3.55 | 3.4              | 3.8  | 四相编码 | 0.84   | 0.96 | 2     |
| 4     | 4.39       | 4.81  | 2.75              | 3.95 | 3                | 4.2  | 四相编码 | 0.48   | 0.87 | 2     |
| 5     | 9.64       | 9.96  | 8.6               | 9.09 | 2.41             | 2.99 | 线形调频 | 0.68   | 0.92 | 3     |
| 6     | 8.81       | 9.39  | 8.41              | 9.28 | 2.18             | 3.22 | 二相编码 | 0.44   | 0.86 | 1     |
| 7     | 4.35       | 4.85  | 2.63              | 4.07 | 2.88             | 4.32 | 四相编码 | 0.36   | 0.84 | 2     |
| 8     | 8.96       | 9.24  | 8.64              | 9.05 | 2.45             | 2.95 | 二相编码 | 0.72   | 0.93 | 1     |
| 9     | 9.54       | 10.06 | 8.45              | 9.24 | 2.23             | 3.17 | 线形调频 | 0.48   | 0.87 | 3     |
| 10    | 4.56       | 4.64  | 3.24              | 3.46 | 3.49             | 3.71 | 四相编码 | 0.88   | 0.97 | 2     |
| 11    | 4.54       | 4.66  | 3.18              | 3.52 | 3.43             | 3.77 | 四相编码 | 0.84   | 0.96 | 2     |
| 12    | 9.64       | 9.96  | 8.6               | 9.09 | 2.41             | 2.99 | 线形调频 | 0.68   | 0.92 | 3     |
| 13    | 9.05       | 9.15  | 8.77              | 8.92 | 2.61             | 2.79 | 二相编码 | 0.88   | 0.97 | 1     |
| 14    | 9.68       | 9.93  | 8.66              | 9.03 | 2.48             | 2.93 | 线形调频 | 0.76   | 0.94 | 3     |
| 15    | 8.88       | 9.32  | 8.51              | 9.18 | 2.29             | 3.11 | 二相编码 | 0.56   | 0.89 | 1     |

在测试阶段, 标量类型和区间类型的测试样本各有 120 个, 对应每个辐射源型号 40 个. 首先利用无误差测试样本 (无误差标量类型和区间类型的测试样本均来自辐射源样本库) 进行测试, 然后再利用 4.1 节的方法将无误差数据加测量误差得到不同误差等级的测试样本. 为了与文献 [9] 中的 NVTBP 算法作比较, EDL 的取值为 (0~20%), 测试结果如表 6 所示.

从表 6 中可看出, 当 EDL 的取值为 0 时, CMVNN 算法对标量类型测试样本的识别率比 NVTBP 算法高出约 25%, 对区间类型测试样本的识别率比 NVTBP 算法高

出约 22%;随着 EDL 的增加,CMVNN 算法的优势越来越明显,当 EDL 的取值为 20%时,CMVNN 算法对标量类型测试样本的识别率为 91.35%,对区间类型测试样本的识别率为 90.68%,分别比 NVTBP 算法高出约 31%和 25%。这主要由于 CMVNN 算法在训练过程中利用了脉内调制 MOP 及其特征可靠系数信息,提高了分类识别的精度。两种算法的识别效果对比图如图 6 所示。

表 6 实验 2 的识别结果

| 误差偏离水平 (%) | 标量类型测试样本    |             | 区间类型测试样本    |             |
|------------|-------------|-------------|-------------|-------------|
|            | NVTBP 算法    | CMVNN 算法    | NVTBP 算法    | CMVNN 算法    |
|            | 总的平均识别率 (%) | 总的平均识别率 (%) | 总的平均识别率 (%) | 总的平均识别率 (%) |
| 20         | 60.94       | 91.35       | 65.95       | 90.68       |
| 18         | 62.05       | 92.60       | 66.19       | 93.63       |
| 16         | 62.19       | 94.87       | 66.50       | 96.63       |
| 14         | 62.19       | 97.00       | 66.69       | 98.18       |
| 12         | 62.75       | 98.15       | 66.94       | 99.37       |
| 10         | 62.88       | 99.63       | 67.44       | 99.82       |
| 8          | 67.98       | 100         | 72.80       | 100         |
| 6          | 68.51       | 100         | 75.24       | 100         |
| 4          | 68.98       | 100         | 77.04       | 100         |
| 2          | 73.88       | 100         | 77.50       | 100         |
| 0          | 74.60       | 100         | 78.35       | 100         |




图 6 实验 2 两种算法的识别效果

图 6(a)为标量类型测试样本的识别效果对比图,图 6(b)为区间类型测试样本的识别效果对比图。从图 6 同样可以看出,CMVNN 算法比 NVTBP 算法具有更好的测量误差适应能力,并且随着 EDL 的增加,CMVNN 算法的性能呈缓慢下降的趋势。因此可以得出与 NVTBP 算法相比,CMVNN 算法不但具有更好的识别能力,而且

具有更好的测量误差适应性。

### 4.3 实测数据实验

本实验中,利用实测数据来验证 CMVNN 算法与模糊匹配法对雷达辐射源的识别能力。辐射源特征采用载频  $RF$ 、脉冲重复间隔  $PRI$ 、脉宽  $PW$  和脉内调制  $MOP$  四个参数。训练样本中不仅有连续型特征参数的定量区间值,而且还有连续型和离散型特征参数的定性概念值,测试样本为定量区间值。对该 3 类辐射源识别问题,CMVNN 算法由 3 个网络结构为 4-3-1 的矢量神经网络 VNN 组合而成,训练步长  $\eta = 0.02$ ,惯性项系数  $\alpha = 0.9$ ,最大允许输出误差  $E_{\max} = 0.005$ ;模糊匹配法采用正态型隶属度函数,并且对离散型特征参数进行识别时仅考虑是否匹配两种情况。

首先利用无误差测试样本(标量类型和区间类型)进行测试,然后再利用 4.1 节的方法将无误差数据加测量误差得到不同误差等级的测试样本。为了与模糊匹配法作比较,EDL 的取值为(0~10%),测试结果如表 7 所示。

表 7 实验 3 的识别结果

| 误差偏离水平 (%) | 标量类型测试样本    |             | 区间类型测试样本    |             |
|------------|-------------|-------------|-------------|-------------|
|            | NVTBP 算法    | CMVNN 算法    | NVTBP 算法    | CMVNN 算法    |
|            | 总的平均识别率 (%) | 总的平均识别率 (%) | 总的平均识别率 (%) | 总的平均识别率 (%) |
| 10         | 56.95       | 83.50       | 57.01       | 85.19       |
| 8          | 57.83       | 84.12       | 57.10       | 86.88       |
| 6          | 60.73       | 87.75       | 66.52       | 88.31       |
| 4          | 65.19       | 89.31       | 74.76       | 92.16       |
| 2          | 73.05       | 91.06       | 75.20       | 94.22       |
| 0          | 75.53       | 91.25       | 75.50       | 94.63       |

从表 7 中可以看出,当 EDL 的取值为 0 时,CMVNN 算法对标量类型测试样本的识别率比模糊匹配法高出约 16%,对区间类型测试样本的识别率比模糊匹配法高出约 19%;当 EDL 等于 10%时,CMVNN 算法对标量类型测试样本的识别率为 83.50%,对区间类型测试样本的识别率为 85.19%,分别比模糊匹配法高出约 27%和 28%。这主要是由于 CMVNN 算法在训练过程中利用了定性的训练样本数据及训练样本本身的可靠性而提高了网络的分类识别精度造成的。

从上述三个实验中还可以看出,CMVNN 算法不仅能处理数字类型的输入变量,而且能处理语义类型的输入变量(连续型特征参数和离散型特征参数的定性概念值),并且由于在训练过程中利用了特征参数的调制类型信息及样本的可靠系数,提高了网络的分类识别能力。

## 5 结论

矢量神经网络是进行辐射源识别的重要工具,但

是其在训练时没有考虑训练样本本身的可靠性及语义信息的处理,容易造成辐射源分类识别的精度变差.本文对上述问题进行研究,提出了一种基于云模型和改进型矢量神经网络(CMVNN)的识别算法,并通过仿真实验验证了本文算法的有效性.得到结论如下:

(1)CMVNN算法不仅能处理语义类型的输入矢量,而且能够处理数字类型的输入矢量,并且在测量误差环境中具有较高的识别率.

(2)利用云模型能够实现连续型特征参数及离散型特征参数的定性概念值到一定置信度定量区间值的转换.

(3)本文提出的样本可靠系数的计算方法考虑了辐射源各个不同特征参数的可靠系数及其在总的可靠系数中所占的比重,能够提高网络的分类识别能力.

#### 参考文献:

- [1] Spezio A E. Electronic warfare systems[J]. IEEE Transactions on Microwave Theory and Techniques, 2002, 50(3): 633 - 644.
- [2] Huo Q, Lee C. A bayesian predictive classification approach to robust speech recognition[J]. IEEE Transactions on Speech and Processing, 2000, 8(2): 200 - 204.
- [3] Hassan S A, Bhatti A I, Latif A. Emitter recognition using fuzzy inference system[A]. Proceedings of IEEE International Conference on Emerging Technologies (ICET 2005) [C]. Islamabad, Pakistan: IEEE, 2005. 204 - 208.
- [4] Zuo W M, Zhang D, Wang K Q. On kernel difference-weighted k-nearest neighbor classification[J]. Pattern Analysis and Applications, 2008, 11(3-4): 247 - 257.
- [5] 关欣, 何友, 衣晓. 一种新的基于粗集的辐射源信号识别模型[J]. 宇航学报, 2007, 28(3): 685-688.  
Guan Xin, He You, Yi Xiao. A novel rough set emitter signal recognition model[J]. Journal of Astronautics, 2007, 28(3): 685 - 688. (in Chinese)
- [6] 王杰贵, 靳学明, 罗景青. 基于ESM与ELINT信息融合的机载辐射源识别[J]. 电子学报, 2006, 34(3): 424 - 428.  
WANG Jie-gui, JIN Xue-ming, LUO Jing-qing. Airborne emitter recognition based on multisensor data fusion of ESM and ELINT[J]. Acta Electronica Sinica, 2006, 34(3): 424 - 428. (in Chinese)
- [7] Polikar R, Udpa L, Udpa S S, Honavar V. Learn++: An incremental learning algorithm for supervised neural networks[J]. IEEE Transactions on Systems, Man, and Cybernetics, 2001, 31(4): 497 - 508.
- [8] Ishibuchi H, Fujioka R, Tanaka H. Neural networks that learn from fuzzy if-then rules[J]. IEEE Transactions on Fuzzy Systems, 1993, 1(2): 85 - 97.
- [9] Shieh C, Lin C. A vector neural network for emitter identification[J]. IEEE Transactions on Antennas and Propagation, 2002, 50(8): 1120-1127.
- [10] Li D, Han J, Shi X, Chan M. Knowledge representation and discovery based on linguistic atoms[J]. Knowledge-Based System, 1998, 10: 431 - 440.
- [11] 李德毅. 知识表示中的不确定性[J]. 中国工程科学, 2000, 2(10): 73 - 79.  
Li D Y. Uncertainty in knowledge representation[J]. Engineering Science, 2000, 2(10): 73 - 79. (in Chinese)
- [12] 李德毅, 刘常昱, 杜 ■, 韩旭. 不确定性人工智能[J]. 软件学报, 2004, 15(11): 1583 - 1594.  
Li D Y, Liu C Y, Du Y, Han X. Artificial intelligence with uncertainty[J]. Journal of Software, 2004, 15(11): 1583 - 1594. (in Chinese)
- [13] 李德毅, 刘常昱. 论正态云模型的普适性[J]. 中国工程科学, 2004, 6(8): 28 - 34.  
Li D Y, Liu C Y. Study on the universality of the normal cloud model[J]. Engineering Science, 2004, 6(8): 28 - 34. (in Chinese)
- [14] 黄海生, 王汝传. 基于隶属云理论的主观信任评估模型研究[J]. 通信学报, 2008, 29(4): 14 - 19.  
HUANG Hai-sheng, WANG Ru-chuan. Subjective trust evaluation model based on membership cloud theory[J]. Journal on Communications, 2008, 29(4): 14 - 19. (in Chinese)
- [15] 宋远骏, 李德毅, 杨孝宗, 崔东华. 电子产品可靠性的云模型评价方法[J]. 电子学报, 2000, 12(28): 74 - 76.  
Song Yuan-jun, Li De-yi, Yang Xiao-zong, Cui Dong-hua. Reliability evaluation of electronic products based on cloud models[J]. Acta Electronica Sinica, 2000, 12(28): 74 - 76. (in Chinese)
- [16] Wang Fang, Li Yanpeng, Li Xiang. Performance evaluation for automatic target recognition based on cloud theory[A]. The 2008 International Conference on Radar [C]. Adelaide, SA: IEEE, 2008. 498 - 502.

#### 作者简介:

刘海军 男, 1982 年生于山东德州, 国防科大电子科学与工程学院博士, 讲师, 主要研究方向为辐射源识别、信号处理和综合电子战. E-mail: boy8263@yahoo.cn

柳 征 男, 1978 年生, 博士, 讲师, 研究方向为辐射源识别技术.

姜文利 男, 1967 年生, 博士, 教授, 博导. 研究方向为综合电子战技术、空间信息处理等.

周一宇 男, 1948 年生, 博士, 教授, 博导. 研究方向为综合电子战技术、无源定位和空间信息处理等.