

doi: 10.7690/bgzdh.2022.09.014

## 基于雷达高分辨距离像序列识别的研究综述

卢中原<sup>1</sup>, 王中训<sup>1</sup>, 但波<sup>2</sup>

(1. 烟台大学物理与电子信息学院, 山东 烟台 264005; 2. 海军航空大学岸防兵学院, 山东 烟台 264001)

**摘要:** 为了解雷达目标更多的详细信息, 对基于高分辨距离像 (high resolution range profile, HRRP) 序列的目标识别方法进行分析。对隐马尔可夫模型 (hidden Markov model, HMM)、卷积神经网络 (convolutional neural network, CNN)、循环神经网络 (recurrent neural network, RNN) 和长短期记忆网络 (long short-term memory, LSTM) 等面向序列识别的分类器进行阐述和讨论, 分析不同分类器用于 HRRP 目标识别的发展历程, 指出不同识别方法的优缺点及适用性条件。结果表明, 该研究可为不同识别场景下应用合适的分类器提供一些思路。

**关键词:** 高分辨距离像; 雷达; 序列识别; 人工智能; 雷达自动目标识别

**中图分类号:** TP183 **文献标志码:** A

## A Survey of Recognition Research Based on Radar HRRP Sequence

Lu Zhongyuan<sup>1</sup>, Wang Zhongxun<sup>1</sup>, Dan Bo<sup>2</sup>

(1. School of Physics and Electronic Information, Yantai University, Yantai 264005, China;

2. College of Coast Guard, Naval Aviation University, Yantai 264001, China)

**Abstract:** In order to get more detailed information of radar target, the target recognition method based on high resolution range profile (HRRP) sequence is analyzed. A hidden Markov model (HMM), a convolution neural network (CNN), a recurrent neural network (RNN), and long short-term memory (LSTM), analyzes the development process of different classifiers for HRRP target recognition, and points out the advantages, disadvantages and applicability conditions of different recognition methods. The results show that this study can provide some ideas for the application of appropriate classifiers in different recognition scenarios.

**Keywords:** HRRP; radar; sequence recognition; artificial intelligence; radar automatic target recognition

### 0 引言

随着现代军事电子技术的快速发展, 现代战争对信息化探测技术的需求也更加迫切, 常规雷达只能提供目标的位置信息, 为进一步了解更多关于目标种类、型号等详细信息, 对雷达自动目标识别 (radar automatic target recognition, RATR)<sup>[1]</sup>提出了更高的要求。特别是在国土防空、对海监视等领域, 迫切需要对飞机和舰船目标的分类识别, 从而提高部队指挥控制系统的自动化和智能化水平及其预警能力。

高分辨距离像是用宽带雷达信号获取的目标散射点回波在雷达射线方向上投影的向量和, 包含了丰富的目标信息, 如目标大小、散射体分布等; 因此, 雷达高分辨距离像 (HRRP) 目标识别已经受到了雷达目标识别界的高度关注<sup>[2]</sup>, 对目标识别有重要意义。在高分辨雷达中, 目标占据数十个距离单元, 由此产生的高分辨距离像已经被证实为有效的目标特征。此外, HRRP 是 1 维的, 且 HRRP 易

于获取和计算的特性使其成为 ATR 系统在实际场景中非常有吸引力的目标特征<sup>[3]</sup>。

基于 HRRP 序列的雷达目标识别方法可以总结为 4 类:

1) 基于隐马尔可夫模型 (HMM) 的 HRRP 序列识别。

HMM 是一种基于时间序列的概率统计模型, 通过从 HMM 一个状态到下一个状态的转移概率来描述 HRRP 之间的统计关系, 利用了 HRRP 序列中的时间依赖性。

2) 基于卷积神经网络 (CNN) 的 HRRP 序列识别。

CNN 是一类包含卷积计算且具有深度结构的深度神经网络, 将其用于 HRRP 目标识别, 能够利用其表征学习能力来缓解 HRRP 目标识别中的平移敏感型问题。

3) 基于循环神经网络 (RNN) 的 HRRP 序列识别。

收稿日期: 2022-05-07; 修回日期: 2022-06-23

作者简介: 卢中原 (1998—), 男, 山东人, 硕士, 从事雷达目标识别研究。E-mail: lu\_zhong\_yuan@163.com。

RNN 是一种处理时间序列数据的模型，基于 RNN 的深度学习利用 HRRP 数据中存在的时序相关性对目标物理结构进行建模和描述，来完成对 HRRP 的目标分类。

4) 基于长短期记忆网络(LSTM)的 HRRP 序列识别。

LSTM 是一种特殊的 RNN。相比普通的 RNN 而言，LSTM 加入了一个放置输入门、遗忘门和输出门的 cell，用来判断输入的 HRRP 信息是否有用，将有用的信息留下，经过遗忘门遗忘掉不重要的信息。

近年来，随着相关识别技术的不断提升，基于 HRRP 序列的识别方法也在不断发展。相比常规特征提取方法，基于深度神经网络的特征提取方法可以考虑到 HRRP 数据中有效的深层特征，来获取良好的识别性能<sup>[4]</sup>。笔者分析了 HMM、CNN、RNN 和 LSTM 4 种网络模型的基本结构以及在目标识别中的具体应用，并对其优缺点进行了详细说明。

### 1 基于 HMM 的 HRRP 序列识别

#### 1.1 HMM 基本原理

HMM 是关于时间序列的概率模型<sup>[5]</sup>，描述由一个隐马尔可夫链生成不可观测的状态随机序列，再由每个状态序列生成观测随机序列的过程。其中隐藏的随机过程是不可观测的，只能通过产生的观测序列观察到。Liao X J<sup>[6]</sup>和 Bharadwaj<sup>[7]</sup>利用目标-传感器方向中多个 HRRP 的时间依赖性，相继提出了基于 HMM 的 HRRP 序列识别算法，通过从 HMM 一个状态到下一个状态的转移概率来描述 HRRP 序列之间的统计关系，考虑了 HRRP 序列之间的平稳特性。

HMM 定义：

$t$  时刻模型的状态  $q_t \in \{S_1, S_2, \dots, S_N\}$ ， $t$  时刻的观察值  $O_t \in \{V_1, V_2, \dots, V_M\}$ ，状态转移矩阵  $A = \{a_{ij}\} N \times N$ ， $a_{ij}$  是  $t$  时刻所处的状态  $S_i$  转移到  $t+1$  时刻状态  $S_j$  的状态转移概率。其中： $a_{ij} = P(q_{t+1} = S_j | q_t = S_i)$ ， $1 \leq i, j \leq N$ 。

观测值概率矩阵  $B = \{b_{jk}\} N \times M$ ， $b_{jk}$  是在状态  $S_j$  下得到符号  $V_k$  的概率，即  $b_{jk} = P(O_t = V_k | q_t = S_j)$ ， $1 \leq j \leq N, 1 \leq k \leq M$ 。

模型在初始时刻各状态出现的概率，通常记为  $\pi = (\pi_1, \pi_2, \dots, \pi_N)$ ， $\pi_i = P(q_1 = S_i)$ ， $1 \leq i \leq N$ 。

通过上述参数，就能确定一个 HMM<sup>[8]</sup>：

$$\lambda = [A, B, \pi]$$

图 1 所示为一个典型的 HMM 结构。




图 1 HMM 结构

#### 1.2 基于 HMM 的 HRRP 序列识别研究

文献[9]提出了一种基于动态多任务学习 (multi-task learning, MTL) 的 HMM。在飞机测量数据上检验了所提模型的性能。结果表明：动态 MTL 模型比独立 MTL 模型的识别性能更好；此外，训练数据集越大，识别率越高，越稳定。

文献[10]提出一种多任务学习的截断 Stick-Breaking 过程的 HMM 模型 (multi-task learning truncated stick-breaking, MTL TSB-HMM)。利用目标散射回波序列的时间依赖性，对序列散射数据进行了建模，基于 3 架实际飞机的实测数据，在识别阶段，从不同的数据段中训练数据和测试数据，选择 33 个距离单元的窗口长度和 16 个距离单元的重叠长度进行了谱图特征提取，实验结果表明，MTL TSB-HMM 平均识别率为 95.1%，比 STL TSB-HMM 的平均识别率高 2.3%，有很好的识别效果。

文献[11]针对雷达对目标可获得的大角域信息，提出一种基于分层识别算法的空时融合 HMM 模型 (STF-HMM)。对小角域目标每帧的距离像样本直接进行非相干平均后将其输入 SHMM 模型进行匹配识别；对于大角域距离像样本而言，需要先对 MTRC 进行帧划分，然后对距离像样本进行非相干平均后再将其输入 THMM 模型，综合大小角域识别结果，来判断识别是否正确。通过获知目标的初始方位角及方位角的变化区间，可以减少匹配识别时的运算量。通过对舰船目标的仿真数据和民用船只的实际测量数据分析，验证了该方法的有效性。

雷达总是在检测到目标后进行识别，对于海雷达系统来说，可以在一段时间内通过多次观测获得目标的序列回波信号，例如：对相控阵雷达，可以利用其波束灵活可控的特点对目标多次观测得到序

列目标回波；对搜索和跟踪雷达，可以在目标航迹建立后得到各个目标的序列回波。将 HMM 模型用于雷达 HRRP 目标识别虽然取得了很好的表现，但仍存在一些不足：

1) 当目标状态数越多，在识别时搜索最佳路径来计算 HRRP 序列的最大后验概率的运算量也就越大<sup>[12]</sup>。

2) 由于目标在 3 维空间中运动，相应的运动姿态在 3 维空间中也会发生变化；因此，在 HMM 训练和识别中如何对 HRRP 序列进行选取是需要考虑的一个问题。

基于上述局限性，引入神经网络结构能够减少传统识别算法中特征提取等步骤的计算量，卷积神经网络可以对非常复杂数据量大的数据进行分类，

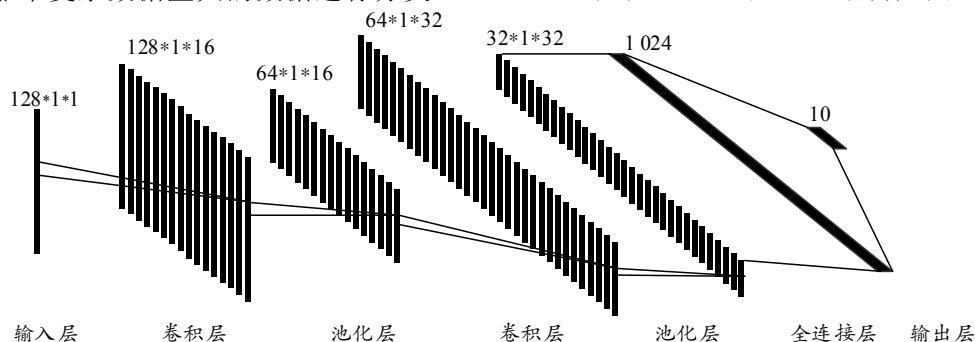


图 2 针对 HRRP 的 CNN 结构

输入层的作用主要是对原始数据进行预处理，使数据具有相同的维数，并将输入数据送入卷积层提取特征信息。预处理可以减少同一目标不同 HRRP 数据因幅值变化大而对特征提取的影响，在梯度下降的同时，加快网络模型的收敛速度。预处理的方式主要包括对 HRRP 数据幅值进行归一化处理，对归一化后的数据去均值。

卷积层是 CNN 与其他神经网络结构最大的区别，主要用于提取输入 HRRP 数据的特征信息，通常包含多个可学习的卷积核，每个卷积核元素有其权重参数和偏置。卷积核与输入数据进行卷积运算，将结果保存到输出的对应位置并送入激活函数进行激活，就可以得到输出特征。计算过程为：

$$x_j^l = f \left( \sum_{i \in M_j} x_i^{l-1} * k_{ij}^l + b_j^l \right) \quad (1)$$

式中： $x$  为特征项； $M$  为输入特征项的集合； $k$  为可学习的卷积核； $b$  为偏差值； $l$ 、 $i$  和  $j$  分别为网络结构层、卷积核和特征项通道的序号； $f$  为激活函数。卷积层包括卷积核尺寸、卷积核数量、卷积步长、特征补零的方式和激活函数等参数，常用的

在图像处理中具有很大的优势，故基于 CNN 的 HRRP 目标识别也引起了广泛关注。

## 2 基于 CNN 的 HRRP 序列目标识别

### 2.1 CNN 基本原理

CNN 是一种著名的深度学习结构<sup>[13]</sup>，由于卷积、池化过程中的平移不变性，将其用于提取 HRRP 数据中的平移不变特征具有很好的效果，减少对 HRRP 数据预处理的运算量，具有良好的鲁棒性。卷积神经网络主要包括 5 部分：输入层、卷积层、池化层、全连接层、输出层<sup>[14]</sup>。通过将这些层叠加起来，就可以构建一个卷积神经网络用于 HRRP 目标识别。

针对 HRRP 的 CNN 结构如图 2 所示。

激活函数包括 Sigmoid 函数、Tanh 函数、Relu 函数等<sup>[15]</sup>。

池化层一般在卷积层后，池化层通过抑制提取特征中的冗余信息来减少模型的计算量，即对特征进行降维从而避免过拟合，同时还使得池化输出的特征具有平移不变特性。常见的池化层操作包括最大池化、中值池化、均值池化等。

全连接层通常放置在神经网络的末端，其主要功能是对前一层得到的特征进行重新拟合，得到 1 维向量，通过输出层分类器输出结果。常用的分类器有 softmax 和支持向量机等。

图 3 所示为利用卷积神经网络进行特征提取的基本流程。

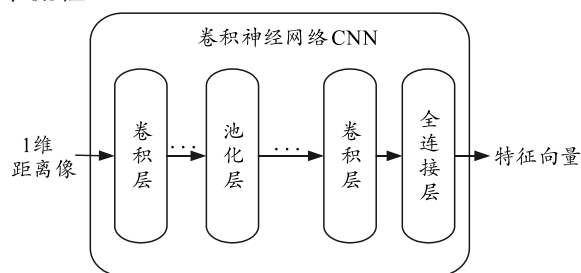


图 3 利用卷积神经网络进行特征提取

### 2.2 基于 CNN 的 HRRP 序列识别研究

文献[16]将 CNN 应用在舰船高分辨距离像目标识别上，通过对 HRRP 数据重新排列将其转化成 2 维数据作为 CNN 的输入，实验测得 5 类舰船在不同角度下的 HRRP 数据，每类包含 2 400 个样本，将其中 80% 的数据用于训练网络，剩余 20% 用于测试网络，并将其与 SVM 进行比较。结果表明：CNN 的识别性能在识别精度和识别时间上均优于 SVM，并且在添加噪声的情况下，CNN 的识别率仍要优于 SVM，具有很好的鲁棒性。

文献[17]比较 2 种不同的 CNN 结构进行 HRRP 目标识别。一种是将 HRRP 数据转换成 2 维图像输入，卷积层中采用  $n \times n$  的卷积核；另一种是将 HRRP 数据直接输入网络中，卷积层中采用  $1 \times n$  的卷积核，实验采用 6 种实测 HRRP 数据作为 2 种网络模型的输入，并用相同数据与模板匹配法进行比较。结果表明：采用 CNN 的识别方法比模板匹配法识别准确率提高了 20%，且将 HRRP 数据直接输入 CNN 比转换成 2 维图像输入识别准确率更高。

文献[18]利用 CNN 模型对 10 种不同的舰船目标进行分类，其中 6 艘为军用船，4 艘为民用船。首先获取舰船目标的 HRRP 数据并对其进行归一化处理，使幅度值在 0~1 之间，然后将  $1 \times 168$  的 HRRP 数据复制 32 次将其转化成  $32 \times 168$  的数据图像。为每种舰船准备了 910 个数据图像，随机选择其中 75% 的图像用于训练，剩余的图像用于测试。测试结果表明：该模型对 10 种舰船的平均识别率为 93.90%，验证了 HRRP 形成的数据图像用于舰船目标分类是可行的。

CNN 利用 HRRP 相邻距离单元的局部相关性，通过卷积层对 HRRP 进行层次化抽象来获得更高级的特征表示。具有权值共享和局部连接的特点，可以自动地从要处理的高分辨距离像中提取特征，但也存在着一些不足：

1) 神经网络在训练的过程中，虽然可以自动地提取数据特征，但在池化的过程中也会舍弃掉部分信息，不能很好地利用数据内部的时序相关性；

2) HRRP 作为 1 维信号，若将其转化成 2 维数据输入 CNN，可能会破坏 HRRP 数据的内部结构，遗漏掉很多重要的特征信息。

卷积网络结构的优势在于提取输入数据的位置关系，而 HRRP 数据间的时间关系更值得研究，RNN 处理具有序列特性的数据非常有效，故被广泛应用

于序列数据处理中。

## 3 基于 RNN 的 HRRP 序列目标识别

### 3.1 RNN 基本原理

RNN 是一种应用十分广泛的神经网络模型<sup>[19]</sup>。该模型具有记忆特性，能够处理序列数据；因此，非常适合于对 HRRP 中包含的目标物理结构特征进行建模。基本循环网络结构包括一个输入层、一个隐藏层和一个输出层。 $X$  是输入层的值； $h$  是隐藏层的值； $L$  是损失函数； $f, g$  为激活函数。输入层与隐藏层之间的连接由权值矩阵  $U$  参数化， $O$  是输出层的值，隐藏层与输出层之间的连接由权值矩阵  $V$  参数化。其中隐藏层的值  $h$  不仅取决于当前时刻的输入  $x$ ，还取决于上一时刻隐藏层的值  $h$ ，隐藏层与隐藏层之间的连接由权值矩阵  $W$  参数化。更新方程如下：

$$h^{(t)} = f(W h^{(t-1)} + U x^{(t)} + b); \tag{2}$$

$$o^{(t)} = g(V h^{(t)} + c); \tag{3}$$

$$\hat{y}^{(t)} = \text{softmax}(o^{(t)}). \tag{4}$$

图 4 所示为一个典型的 RNN 结构。

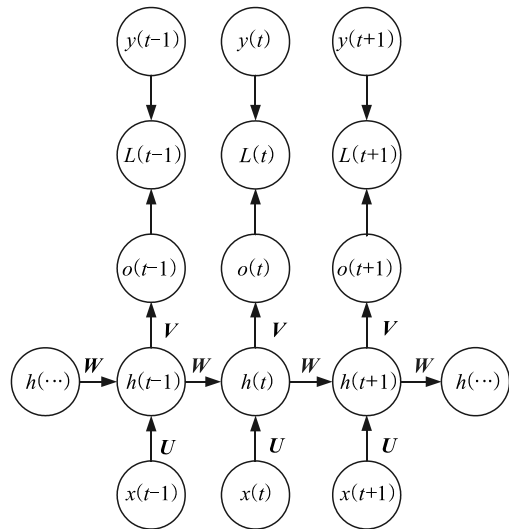


图 4 RNN 结构

### 3.2 基于 RNN 的 HRRP 序列识别研究

近年来，循环神经网络在 HRRP 目标识别领域取得了一些进展。

文献[20]针对 RNN 经常出现的梯度消失问题，提出了一种梯度稳定循环神经网络 (gradient stabilized recurrent neural network, GS-RNN)，应用在 HRRP 序列识别当中，能有效利用相邻 HRRP 之间的时空相关性，避免梯度消失问题，该方法主要包括对缺失样本进行估计、对模型进行训练和输出

识别结果 3 个步骤。识别过程分为 3 个步骤：1) 利用 GS-RNN 估计缺失样本，得到完整的样本集；2) 对网络参数进行训练，得到最优网络参数；3) 利用 MSTAR, SAR 数据转换的 HRRP 序列进行实验验证模型的有效性。实验表明：该模型在不缺失估计样本的情况下优于传统方法，同时在低信噪比的条件下仍有比较好的识别准确率。

文献[21]提出了一种目标感知的 2 维循环神经网络(target aware two-dimensional recurrent neural network, TATDRNN)，引入 2 维 RNN 分别对 HRRP 数据的目标区域和噪声区域进行建模，并定义贝叶斯生成模型，根据目标区域和噪声区域的分布特征进行分离。改进了 RNN 的参数共享机制，信号的目标和噪声共享不同的参数，有效地从噪声中分离目标，从 3 架真实飞机测得的 HRRP 数据来检测模型，通过比较目标识别性能与几种现有的方法，包括最大相关系数(maximum correlation coefficient, MCC)、自适应高斯分类器(adaptive gaussian classifier, AGC)、全连接网络(fully connected network, FCN)、线性动态系统(linear dynamic system, LDS)等，模型 TATDRNN 得到了最优识别精度结果。

文献[22]提出了一种乘性循环神经网络(multiplicative recurrent neural network, MRNN)来解决时序相关性变化与参数固定模型不匹配的问题。首先将 HRRP 样本数据转化为序列数据，然后针对不同输入的序列数据自适应的选择相应的参数，最后采用投票的方式融合时序信息，输出识别结果。用实测飞机数据验证了模型的性能，并将该模型同多种传统 HRRP 目标识别方法进行比较，实验结果表明，MRNN 识别准确率为 93.3%，高于传统 HRRP 目标识别方法准确率。

文献[23]提出了一种基于循环神经网络的注意模型，将该模型应用在 HRRP 时域特征的训练阶段和测试阶段，对 HRRP 中不同距离单元所起作用的不同，来对不同区域的隐藏层自适应地赋予相应的权值系数。通过实测数据上的实验结果表明，该模型能有效提取特征进行识别，在目标存在偏移的情况下，也能准确找出可识别区域。

RNN 相对于传统的神经网络优势在于其能从时间序列中学习数据特征，进而对目标完成分类。但是 RNN 也存在着不足：

1) RNN 通过类似滑窗的过程处理数据，在每个

时刻的连接权重是相同的，在每个时刻的输入仅与上个时刻有关，会导致距离当前时刻较远的输入信息会随着时间节点的增加逐渐消失；

2) RNN 提取的特征具有高度冗余性，给后续建模带来了更多困难，只使用当前时刻和之前的信息，没有考虑之后时刻的信息；

3) RNN 在训练时，容易在时间维度上出现梯度爆炸和梯度消失问题，这就极大地限制了传统 RNN 的训练和测试阶段。

针对这种局限性，有学者提出了基于门结构改进的循环神经网络单元，其中 LSTM 对 RNN 有较好的改进效果，有着广泛的应用。

## 4 基于 LSTM 的 HRRP 序列目标识别研究

### 4.1 LSTM 基本原理

长短期记忆(LSTM)是一种特殊的 RNN，由于 RNN 在训练过程中容易出现梯度消失问题，使得 RNN 网络不能记住长时间长距离的依赖性信息，因此提出了 LSTM 网络结构。其核心是设计了输入门、遗忘门和输出门的结构，LSTM 的总流程是先经过遗忘门  $f_t$ ，决定哪些信息需要被丢弃，下一阶段是输入门  $i_t$ ，确定哪些信息需要被存入下一层，最后一个阶段是输出门  $o_t$ ，确定输出什么值。这些操作按以下公式进行：

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f); \quad (5)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i); \quad (6)$$

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tanh(W_c \cdot [h_{t-1}, x_t] + b_c); \quad (7)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o); \quad (8)$$

$$h_t = o_t \cdot \tanh(c_t). \quad (9)$$

LSTM 结构如图 5 所示。

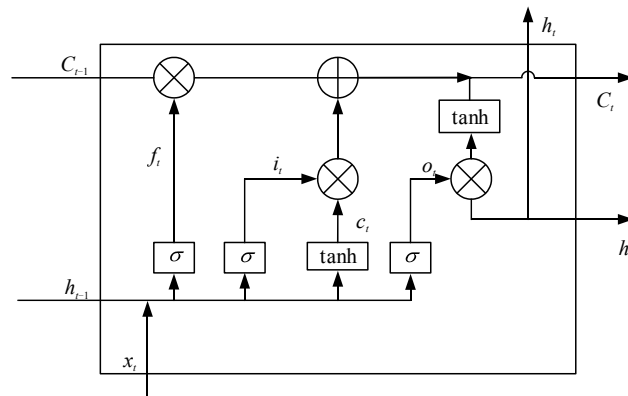


图 5 LSTM 结构

### 4.2 基于 LSTM 的 HRRP 序列识别

文献[24]提出一种结合 LSTM 和 HMM 决策相

结合的 HRRP 目标识别方法, 将 HRRP 序列按方向角进行划分, 建立原始的 HMM, 然后将 HRRP 序列送入 LSTM 网络进行训练, 针对输出序列构造一个改进的 HMM 模型。在识别过程中, 将测试序列输入训练后的 LSTM 网络, 然后将 LSTM 网络输出输入到改进的 HMM 中, 计算各模型输出的条件概率, 另一方面将测试序列直接输入到原始 HMM 中计算概率, 最后, 将原 HMM 和改进 HMM 进行联合决策, 最大概率对应的模型类别为识别结果。实验在 MSTAR 数据库上进行, 同直接为 HRRP 序列构建 HMM、利用单一 LSTM 网络直接训练和识别 HRRP 序列和将 LSTM 网络直接连在 HMM 上这 3 种方法比较。结果表明: 该方法识别率达到 94.82%, 高于其他 3 种方法。

文献 [25] 提出了一种卷积长短时网络 (convolutional long short-term memory, convLSTM) 和注意力机制的极化 HRRP 识别模型。convLSTM 与 LSTM 不同的是, convLSTM 中用于输入到状态和状态到状态转换的全连接运算符被卷积运算符替换, 将原始数据输入到 convLSTM 时, 在每个时间步中使用卷积算子来捕获每个距离单元沿极化维度的散射信息。利用 LSTM 网络结构将这些信息沿空间维度聚合在一起, 形成目标最终特征表示, 在 convLSTM 之前引入自注意力机制, 使模型聚焦于更有辨别能力的距离单元。在仿真数据和实测数据上的实验结果表明了该模型对于多类目标具有很好的识别准确性。

文献 [26] 提出了一种双向长短时记忆模型 (bidirectional long short term memory, BLSTM)。实验中使用的数据是雷达实际测量的飞机数据, 分析了不同隐层维度和窗长对识别性能的影响以及模型只考虑前向序列和后向序列时的性能, 与 HMM 模型、全连接网络、深度置信网络等传统网络模型相比, 识别性能有所提高。

文献 [27] 提出了一种基于长短时记忆网络 RNN 模型的 HRRP 目标识别方法, 利用微软计算网络工具包 (computational network toolkit, CNTK) 进行建模、训练和评估神经网络, 距离像数据通过电磁仿真生成, 仿真中使用了 3 种公共领域的目标模型, 将 175 个 HRRP 用于网络训练, 100 个 HRRP 用于测试。实验结果表明: 该模型对于 3 种目标模型能够有效地识别出来。

文献 [28] 提出了一种基于注意力机制的堆叠长

短时记忆网络 (attention-SLSTM) 模型, 该模型通过堆叠多个 LSTM, 来提取 HRRP 序列更深层次的特征, 针对 LSTM 的梯度消失问题, 引入易于求导的 Elu 函数替换原有的 sigmoid 激活函数, 通过 MSTAR 数据集验证了模型的有效性并同传统的机器学习及深度学习方法做了识别性能对比。实验结果表明: 该模型相比其他模型, 识别率最高。

相比传统的 RNN 网络, LSTM 网络由于其门控单元的存在, 会对当前时刻之前的信息有选择的遗忘和保存, 并将其输入到下一时刻, 可以记住更长时间内的信息, 不会导致网络在处理当前时刻信息时只使用距当前时刻较近时间内的信息。这样在判决时刻就可以利用到数据中的大部分信息, 解决了 RNN 中信息丢失和梯度消失问题, 故可以用于 HRRP 的识别。

## 5 结束语

在雷达对海观测领域, 传统的用于海面目标识别的分类器大多都是针对单个目标的距离像进行建模, 没有充分考虑多个 HRRP 之间的时序相关性; 因此, 在雷达观测系统可获得目标连续 HRRP 序列时, 出现了 HMM、CNN、RNN 以及 LSTM 等用于处理时间序列的分类器。传统分类器主要涉及提取物理意义明确的特征, 人为选择可分性较强的特征对后续的识别至关重要; 并且, 由于分类器训练相对简单, 识别效率较高。基于深度学习的分类器不需要手动提取目标特征, 且由于模型复杂度高, “容量”大, 因此识别准确率高。目前, 在对海目标的样本数据获取上还存在一定困难; 雷达识别研究领域缺乏完备的目标数据库, 在实战情况下很难获取目标各个姿态下的训练样本, 单纯依靠仿真实验数据难以有效支撑真正有效的目标库建设, 实测数据对算法的验证不足, 特征测量的方法研究不够, 新理论新方法用于工程实践还有待深入研究。

## 参考文献:

- [1] 马育才. 雷达自动目标识别系统分析与实现[D]. 西安: 西安电子科技大学, 2010.
- [2] DU L, LIU H W, BAO Z. Radar automatic target recognition based on complex high-resolution range profiles[C]//2006 CIE International Conference on Radar. Shanghai, China, 2006: 1-5.
- [3] LIAO X J, BAO Z, XING M D. On the aspect sensitivity of high resolution range profiles and its reduction methods[C]//Record of the IEEE 2000 International Radar Conference. Alexandria, VA, USA, 2000: 310-315.

- [4] 王俊, 郑彤, 雷鹏, 等. 深度学习在雷达中的研究综述[J]. 雷达学报, 2018, 7(4): 395-411.
- [5] 郭武, 朱明明, 杨红兵. 基于隐马尔科夫模型的 RCS 识别方法研究[J]. 现代雷达, 2013, 35(3): 37-40.
- [6] LIAO X J, RUNKLE P C. Identification of ground targets from sequential high-range-resolution radar signatures[J]. IEEE Trans Aerospace and Electronic System, 2002, 38(4): 1230-1242.
- [7] RUNKLE P R, BHARADWAJ P K, COUCHMANL. Hidden Markov models for multiaspect target classification[J]. IEEE Transactions on Signal Processing, 1999, 47(7): 2035-2040.
- [8] RABINER L R. A tutorial on hidden markov models and selected applications in speech recognition[J]. Proceedings of the IEEE, 1989, 77(2): 257-286.
- [9] DU L, WANG P, LIU H, et al. Radar HRRP target recognition based on dynamic multi-task hidden Markov model[C]//2011 IEEE RadarCon(RADAR). Kansas City, MO, USA, 2011: 253-255.
- [10] PAN M, DU L, WANG P, et al. Multi-task Hidden Markov Model for Radar Automatic Target Recognition[C]//Proceedings of the 2011 IEEE CIE International Conference on Radar. Chengdu, China, 2011: 650-653.
- [11] 但波, 姜永华, 李敬军, 等. 基于空时融合隐马尔科夫模型的舰艇编队目标识别方法[J]. 电子与信息学报, 2015, 37(4): 926-932.
- [12] 刘宏伟, 杜兰, 袁莉, 等. 雷达高分辨距离像目标识别研究进展[J]. 电子与信息学报, 2005(8): 1328-1334.
- [13] GU J X, WANG Z H, KUEN J, et al. Recent advances in convolutional neural networks[J]. Pattern Recognition, 2018, 77: 354-377.
- [14] 严春满, 王铖. 卷积神经网络模型发展及应用[J]. 计算机科学与探索, 2021, 15(1): 27-46.
- [15] 付哲泉, 李相平, 李尚生, 等. 深度学习在雷达目标高分辨距离像识别中的研究综述[J]. 航空兵器, 2020, 27(3): 37-43.
- [16] 张奇, 卢建斌, 刘涛, 等. 基于 CNN 的舰船高分辨距离像目标识别[J]. 雷达科学与技术, 2020, 18(1): 27-33.
- [17] 杨予昊, 孙晶明, 虞盛康, 等. 基于卷积神经网络的高分辨距离像目标识别[J]. 现代雷达, 2017, 39(12): 24-28.
- [18] KARABAYLR O, YÜCEDAĞ O M, KARTAL M Z, et al. Convolutional Neural Networks-Based Ship Target Recognition Using High Resolution Range Profiles[C]//2017 18th International Radar Symposium(IRS). Prague, Czech Republic, 2017: 1-9.
- [19] LIPTON Z C. A critical review of recurrent neural networks for sequence learning[J]. arXiv, 2015: 1506.00019.
- [20] ZHANG Y F, QIAN F C, XIAO F. GS-RNN: A novel RNN optimization method based on vanishing gradient mitigation for HRRP sequence estimation and recognition[C]//2020 IEEE 3rd International Conference on Electronics Technology(ICET). Chengdu, China, 2020: 840-844.
- [21] LIU J Q, CHEN B, CHEN W C, et al. Radar HRRP target recognition with target aware two-dimensional recurrent neural network[C]//2019 IEEE International Conference on Signal Processing, Communications and Computing(ICSPCC). Dalian, China, 2019: 1-6.
- [22] 徐彬, 张永顺, 张秦, 等. 采用乘性 RNN 的雷达 HRRP 目标识别[J]. 西安电子科技大学学报, 2021, 48(2): 49-54.
- [23] 徐彬, 陈渤, 刘宏伟, 等. 基于注意循环神经网络模型的雷达高分辨率距离像目标识别[J]. 电子与信息学报, 2016, 38(12): 2988-2995.
- [24] TU J, HUANG T, LIU X S, et al. A novel HRRP target recognition method based on LSTM and HMM decision-making[C]//2019 25th International Conference on Automation and Computing(ICAC). Lancaster, UK, 2019: 1-6.
- [25] ZHANG L, LI Y, WANG Y H, et al. Polarimetric HRRP recognition based on ConvLstm with self-attention[J]. IEEE Sensors Journal, 2021(6): 7884-7898.
- [26] 徐彬, 陈渤, 刘家麒, 等. 采用双向 LSTM 模型的雷达 HRRP 目标识别[J]. 西安电子科技大学学报, 2019, 46(2): 29-34.
- [27] JITHESH V, SAGAYARAJ M J, SRINIVASA K G. LSTM recurrent neural networks for high resolution range profile based radar target classification[C]//2017 3rd International Conference on Computational Intelligence & Communication Technology(CICT). Ghaziabad, India, 2017: 1-6.
- [28] 张一凡, 张双辉, 刘永祥, 等. 基于注意力机制的堆叠 LSTM 网络雷达 HRRP 序列目标识别方法[J]. 系统工程与电子技术, 2021, 43(10): 2775-2781.