

基于残差连接 LSTM 的雷达目标分类识别方法

袁浩, 张军良

(中国电子科技集团公司 第五十四研究所, 石家庄 050081)

摘要: 近年来随着多种小型智能探测设备的出现(如无人机、小型智能车等), 给传统雷达目标识别方法带来了巨大挑战; 在使用雷达对此类小型目标进行探测时得到的信号回波能量通常较低, 导致在复杂环境噪声与杂波影响下难以使用传统恒虚警(CFAR)目标检测方法对其进行识别; 针对以上问题, 结合深度学习的方法提出一种基于残差连接长短期记忆网络(LSTM, long short-term memory)的多类别雷达目标识别模型, 以同一距离门的相邻时间点的回波序列数据作为样本来设计数据集, 使用多层的 LSTM 网络提取雷达回波样本中的时序信息, 并在网络中加入残差连接以避免网络层数增多出现网络退化问题, 同时将用于多类别分类问题的 CCE (categorical cross-entropy) 函数作为网络的损失函数来训练网络, 实现对包括无人机、智能车、行人以及噪声在内的 4 类目标的识别和分类; 试验结果表明基于残差连接 LSTM 网络的多类别雷达目标识别模型相比于传统恒虚警检测方法具有更高的识别准确率和 F1 值。

关键词: 雷达目标识别; 深度学习; LSTM; 残差连接; 多类别分类

Radar Target Classification and Recognition Method Based on Residual Connected LSTM

YUAN Hao, ZHANG Junliang

(54th Research Institute of CETC, Shijiazhuang 050081, China)

Abstract: In recent years, the emergence of a variety of small smart detection devices (such as UAV, small smart car, etc.) has brought great challenges to traditional radar target recognition methods. By using radar to detect such small targets, the signal echo energy obtained is usually low, which makes it difficult to identify them by using the traditional constant false alarm rate (CFAR) target detection method under the influence of complex environmental noise and clutter. Aiming at the above problems, combining the deep learning method, a multi-class radar target recognition model based on the residual connected Long Short-Term Memory (LSTM) is proposed, the echo sequence data at adjacent time points at the same distance gate is taken as the sample to design the data set, the multi-layer LSTM network is used to extract the timing information in the radar echo samples, and the residual connection is added to the network to avoid the problem of network degradation due to the increase of network layers. At the same time, the CCE (categorical cross entropy) function used for the multi-class classification problem is used as the loss function of the network to train the network and realize the recognition and classification of four types of targets, including UAV, smart car, pedestrian and noise. The experimental results show that the multi-class radar target recognition model based on residual connected LSTM network has the higher accuracy of recognition and the F1 value than the traditional CFAR detection method.

Keywords: radar target recognition; deep learning; LSTM; residual connection; multi category classification

0 引言

雷达是一种主要利用电磁波来探测目标的电子设备, 通过对目标发射电磁波进行照射并接受其回波来获得目标的距离、高度、方位等信息^[1]。因其具有全天候、全天时、作用范围广、穿透能力强等特点^[2], 在军事侦察、目标探测、气象观测等多个领域得到了广泛应用。

近年来随着小型无人机、无人智能车等小型设备的出现, 给雷达目标识别方面带来了巨大挑战。此类设备可以被轻易的投放和回收, 且由于体积小不易被发现, 可轻松潜入各种目标区域进行偷拍和探测, 给生产生活甚至国家

安全带来了巨大隐患。在使用雷达对此类目标进行探测时, 由于其目标小、速度低且种类多样, 接收到的回波能量通常比较低, 在复杂环境的噪声与杂波影响下, 会导致信号回波被背景噪声所覆盖。传统的恒虚警^[3] (CFAR, constant false alarm rate) 处理技术是雷达自动检测系统中一种重要的目标识别方法, 能够根据雷达杂波数据对检测门限进行动态调整, 可以使目标检测概率在虚警概率保持不变的情况下达到最大化^[4]。但该方法要求目标与背景噪声有较大的强度差异^[5], 在这种低信噪比的场景下会受到很大限制, 对目标的识别率较差。

收稿日期: 2022-02-17; 修回日期: 2022-03-11。

基金项目: 河北省重大科技成果转化专项(20285401Z)。

作者简介: 袁浩(1997-), 男, 河北石家庄人, 硕士研究生, 主要从事信号与信息处理方向的研究。

张军良(1967-), 男, 河北武安人, 硕士, 研究员, 主要从事信息处理方向的研究。

引用格式: 袁浩, 张军良. 基于残差连接 LSTM 的雷达目标分类识别方法[J]. 计算机测量与控制, 2022, 30(4): 182-189.

随着计算机计算能力的提升以及神经网络的不断发展, 现如今深度学习发展十分迅速。将深度学习方法引入到雷达目标检测识别中, 能够解决传统方法中人工提取特征困难、模型表达能力不足的问题^[6]。同时深度学习方法能够对目标检测和识别进行一体化实现, 建立从输入数据到输出检测结果的端对端的识别网络^[7]。目前深度学习中的卷积神经网络方法已被应用于许多雷达目标检测和识别场景中。韩子硕^[8]等设计了基于卷积神经网络的深层次特征增强网络, 用于对 SAR 图像舰船的检测问题中; He^[9]等设计了基于卷积神经网络的飞机目标检测算法; KANG^[10]等对目标及其周边特征构建上下文信息, 并以此来训练神经网络, 有效降低了目标虚警。虽然卷积神经网络在雷达目标识别领域得到了广泛的应用, 但在对小型目标的雷达目标识别应用场景中若想达到较高的准确率需要搭建的网络层数较多, 往往需要多个卷积神经网络级联, 导致网络结构设计较为复杂; 另一方面, 在处理雷达回波数据这类时间序列数据时, 卷积神经网络也不能很好的利用样本数据的时序相关性来进行训练。

为减少雷达目标识别模型网络结构的复杂度, 同时考虑到雷达接收的回波数据样本具有时序相关性^[11], 选择相较于卷积神经网络更适合于分析序列数据的循环神经网络模型。在当前研究中, 沈梦启^[12]等提出了一种关于宽带雷达一维高分辨距离像序列的目标识别方法, 先使用卷积神经网络抽取目标的特征, 再使用循环神经网络对序列进行识别, 准确率优于现有的机器学习算法; 杨星鑫^[13]等提出了一种基于 LSTM 的无人机实时飞行参数目标识别方法, 通过构造目标的飞行轨迹特征, 使用雷达探测到的目标飞行数据训练模型, 对无人机目标进行识别; 徐彬^[14]等提出了一种双向 LSTM 模型, 能够从前后两个方向提取雷达高分辨距离像的特征, 提高了目标识别性能, 并且在样本发生平移的情况下仍具有稳健的识别率。

可以看出, 关于循环神经网络在雷达目标分类识别的研究多采用雷达高分辨距离像数据。但是对目标进行高分辨成像需要雷达设备提供较高的带宽, 且对信号处理机的运算性能有较高的要求。而现阶段窄带雷达技术成熟, 造价低, 在很多场景下仍无法被宽带雷达所替换。考虑到窄带雷达目标回波本身无法携带目标的形状、结构等信息。使用雷达同一距离门的目标回波序列构建数据集, 从频域上分析, 目标丰富的微多普勒特征可以用于目标识别, 而循环神经网络模型可以自动提取到这些隐含的特征。因此, 本文采集了窄带雷达实测数据, 提出一种基于残差连接长短期记忆网络的神经网络模型, 用于处理包括小型无人机、小型智能车以及行人在内的多种类别的雷达目标识别问题。通过实验仿真并将识别效果进行对比, 相比于传统的恒虚警检测算法, 该模型对于多类小型目标具有更高的识别准确率。

1 循环神经网络模型

1.1 循环神经网络

循环神经网络 (RNN, recurrent neural network) 是一

种用来分析序列数据的神经网络模型^[15], 可以挖掘出数据中的时序信息^[16], 对于处理雷达信号回波这类具有序列特性的数据非常有效。其网络结构如图 1 所示。




图 1 循环神经网络基本结构

图中, \mathbf{X} 表示输入到网络中的特征向量, \mathbf{U} 表示从输入层到隐藏层的参数矩阵, \mathbf{S} 表示隐藏层向量, \mathbf{V} 表示从隐藏层到输出层的参数矩阵, \mathbf{O} 表示输出层向量。 \mathbf{W} 表示每个时间点之间的权重矩阵, 在每一个时刻隐藏层不仅由该时刻的输入层决定, 还会受到上一时刻隐藏层的影响^[17], 这是循环神经网络能够很好解决序列问题的关键之一。因此 t 时刻的输出 O_t 可表示为:

$$O_t = g(\mathbf{V} \cdot \mathbf{S}_t) \tag{1}$$

$$S_t = f(\mathbf{U} \cdot X_t + \mathbf{W} \cdot S_{t-1}) \tag{2}$$

其中: S_t 、 S_{t-1} 分别代表 t 时刻和 $t-1$ 时刻的隐藏层的值。可以看到隐藏层的 S_t 的数值不仅与该时刻的输入 x_t 有关, 还与前一时刻的隐藏层数值 S_{t-1} 有关, 同时 S_{t-1} 又会与 S_{t-2} 有关, 所以当前时刻的 S_t 包含了其历史时刻的信息。这是循环神经网络区别于传统前向神经网络的特别之处, 这种循环连接收集当前信息的上下文关联的方式, 使得循环神经网络可以更好的处理带有时序特征的信号, 因此在处理雷达目标识别时也能比使用卷积神经网络取得更好的效果。

模型训练过程中, 使用反向传播^[18]的方法 BPTT (back-propagation through time) 对参数进行调整。但在处理雷达目标识别样本序列这种长时间序列时难免会造成梯度爆炸或消失, 这是普通循环神经网络难以被直接应用的原因。

1.2 LSTM 网络

为解决梯度消失或者梯度爆炸的问题, 考虑使用循环神经网络的一种改进网络即长短期记忆网络^[19] (LSTM, long short-term memory) 来设计网络模型。其单元结构如图 2 所示。

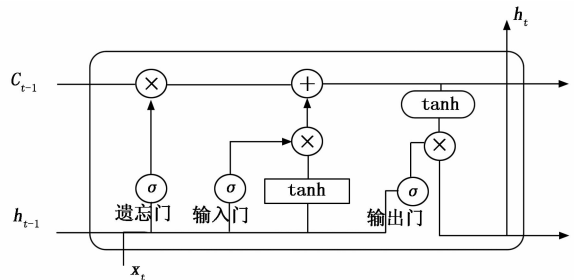


图 2 LSTM 单元结构

可以看到与普通循环神经网络相比, LSTM 的特点是设置了门控机制, 整个门控机制包括遗忘门、输入门和输

出门三个部分^[20]。除门控机制外，LSTM 还增加了记忆状态 C 这一元素^[21]。本期记忆状态值 C_t 由上期状态值 C_{t-1} 经遗忘门过滤到本期的部分以及本期新增的部分所决定。LSTM 网络的反向传播过程计算^[22]如下：

$$\Delta W = -\eta \frac{\partial S}{\partial Y_{\text{predict}}} * \frac{\partial Y_{\text{predict}}}{\partial H_k} * \frac{\partial H_k}{\partial c_k} * \frac{\alpha_k}{\partial c_{k-1}} \dots * \frac{\alpha_2}{\alpha_1} * \frac{\alpha_1}{\partial W} \quad (3)$$

LSTM 模型反向传播过程中通过遗忘门、输入门、输出门等参数的更新调整，可以有效避免普通循环神经网络在网络训练过程中出现梯度爆炸或消失的情况。

2 基于残差连接 LSTM 的多目标识别网络

2.1 多层 LSTM 网络

当面对复杂的分类任务和大量的样本数据时，单隐藏层的 LSTM 网络通常会难以很好地提取样本特征，易导致网络欠拟合^[23]。为解决这一问题，通常使用多层网络来增加网络深度和参数数量，进而能够更好地提取样本特征并提高对复杂样本的拟合能力。因此为解决雷达多类别目标识别的问题，尝试设计多层 LSTM 网络，使用上一层网络的输出作为下一层网络的输入来进行训练，多层 LSTM 网络结构如图 3 所示。

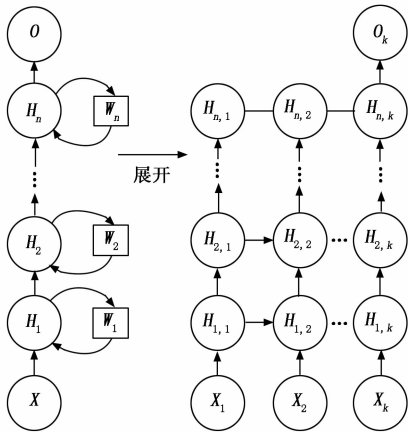


图 3 多层 LSTM 网络结构图

多层 LSTM 网络的每个隐藏层提取到的特征信息都将作为下一层网络的输入，从而达到提取样本数据深层特征信息的目的^[24]，使得网络具备对多类别目标样本的识别和分类能力。多层循环神经网络相比于单层网络，虽然网络的深度和参数规模大大增加，但训练时长并没有大幅增加，且对于雷达目标的识别能达到更好的效果。

2.2 残差结构设计

LSTM 在一定程度上增加网络层数有利于更好提取样本特征，但随着网络层数的增加，模型的训练效果并不总是会得到提升^[25]。在神经网络可收敛的前提下，网络模型的表现往往是随着深度的增加先逐渐趋于饱和之后迅速下降，且这种变化不是由过度拟合引起，这便是网络退化问题。为解决这一问题，何恺明^[26]等在 ResNet 网络中提出了残差连接

概念，主要以跳层连接的形式实现，如图 4 所示。




图 4 残差连接模块

残差模块的输出结果为：

$$H(x) = F(x, w_i) + x \quad (4)$$

其中： x 表示某网络层输入， $H(x)$ 表示期望输出， w_i 表示权重，函数 $F(x)$ 表示待学习的残差映射。理想情况下，深层网络的表现相较于浅层网络应该至少是持平的，但由于非线性激活函数的存在，每一层网络的输入和输出几乎是不可逆的，这就造成了很多不可逆的信息损失。残差连接通过式 (4) 构造恒等映射来解决这一问题，若要让深层网络学习恒等映射 $H(x) \rightarrow x$ ，就等价于令残差分部 $F(x) \rightarrow 0$ ，网络的学习目标从学习完整的输出变为学习如何使残差逼近于 0。通过拟合恒等映射，打破了传统神经网络某一层只能使用上一层的输出作为该层输入的惯例，有利于保证网络不会随着层数增加而发生信息损失，导致网络退化情况的出现。

2.3 基于残差连接 LSTM 的多目标识别模型

由于应用场景涉及到对无人机、小型智能车、行人以及噪声等四类样本，首先对样本种类进行标签化，设置无人机标签为 0，行人标签为 1，智能车标签为 2，噪声标签为 3，之后将类别标签转化为 one-hot 形式：

$$\begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (5)$$

其中，第一行到第四行分别为无人机、行人、智能车和噪声标签的 one-hot 形式。

在对网络进行设计时，网络结构的设置至关重要。如果网络结构设计相对简单，对于数据集的特征信息就难以得到全面表达，导致网络训练发生欠拟合，即与训练集相比，验证集的准确率与损失函数会有较大差距；相反，如果将网络结构设计过于复杂，训练时输入的数据集规模就需要很大，否则可能会发生过拟合的问题，导致在训练集以外的数据集上难以很好的拟合数据。经过多次试验和调整，模型中识别网络结构设计如图 5 所示。

该基于残差连接 LSTM 的网络模型共包含 9 层网络，包括 5 个 LSTM 层和 4 个 Dense 层。每层网络的可处理的序列长度均为 100，其中每个 LSTM 单元内都包含 128 个 cell 单元。数据样本通过输入层进入网络后，经过两层 LSTM 和一层 Dense 层将数据的特征维度扩大为 128。再经

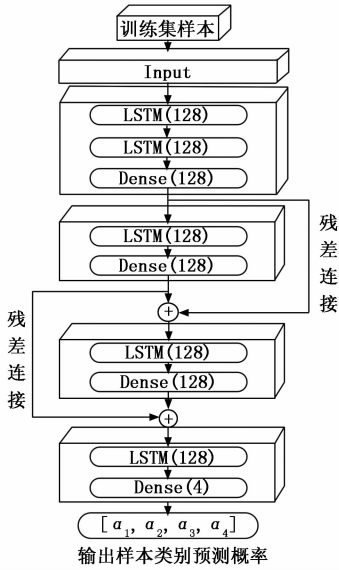


图 5 识别网络结构

过两个 LSTM 层和 Dense 层后, 通过最后一个 LSTM 层进行输出, 将输出结果输入到最后一个 Dense 层得到样本类别预测概率。为了防止发生过拟合, 在每个 LSTM 层中都设计了 dropout 层, 以 0.1 的概率随机对权值进行丢弃。在网络结构中最后两个 LSTM 层的输入处分别加入一个残差连接, 使其能够尽可能拟合恒等映射, 避免产生信息损失导致网络退化情况的出现。

在该模型中, 使用在多类别分类问题当中常用的 Categorical Cross-Entropy (CCE) 函数^[27] 作为损失函数。CCE 函数由激活函数 softmax 和损失函数 Cross-Entropy 两部分组成。softmax 函数形式如下:

$$P(i) = \frac{\exp(z_i)}{\sum_{j=0}^J \exp(z_j)} \quad (6)$$

该函数可以将一个多维的实数向量映射成另一个相同维度的实数向量, 映射后向量中的每个元素均为取值范围在 [0, 1] 之间的实数。通过 softmax 函数的归一化操作, 使得样本类别的输出概率和为 1。便于最后通过输出值对目标进行分类。

Cross-Entropy 函数形式如下:

$$CE = - \sum_{i=1}^N \sum_{j=0}^C y_{i,j} \log \hat{y}_{i,j} \quad (7)$$

其中: y 表示预期输出值, \hat{y} 表示网络模型中经 softmax 激活函数后得到的预期输出值, C 表示类别数量, N 一个批次的样本数。模型网络结构最后一个 Dense 层包含 4 个基本神经元, 分别对应 4 个目标种类计算类别预测概率。输出形式为:

$$P_{predict} = [\alpha_1 \cdot \alpha_2 \cdot \alpha_3 \cdot \alpha_4] \quad (8)$$

其中: 满足 $\alpha_1 + \alpha_2 + \alpha_3 + \alpha_4 = 1$ 。对于最后输出的样本类别预测概率, 设定如下分类判定标准: 若 $\alpha_1 > 0.6$, 则根据之前类别标签的 one-hot 形式, 将该样本判别为 0 号标

签, 即无人机; 同理若 $\alpha_2 > 0.6$, 则将其判别为 1 号标签, 即行人, 以此类推。若 4 个概率值均不大于 0.6, 则不分类。以此为标准来训练网络的识别能力。

3 仿真与结果分析

3.1 实验数据集

采集数据的雷达系统采用线性调频连续波体制。线性调频连续波雷达根据目标回波的差拍信号频率与目标距离成正比的关系, 对目标回波差拍信号进行 FFT 运算, 得到目标距离信息。其处理流程如图 6 所示。

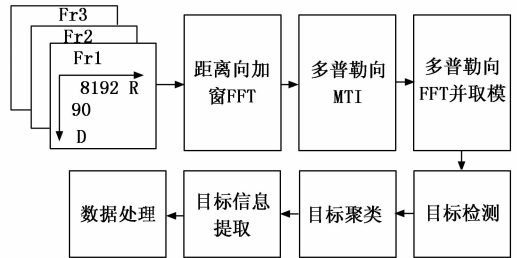


图 6 流程处理图

这里选择将雷达 MTI 处理输入前的距离维解调数据作为数据集, 实验中使用的数据样本由实测得到, 目标的类别包括行人、智能车、无人机和接受机噪声, 以距离门为单个样本单元并标注信号类别标签构建数据集、验证集和测试集。最后得到四类目标样本, 样本特征的两个维度为 IQ 正交两路信号, 样本样例如图 7~10 所示。




图 7 无人机雷达回波样本样例




图 8 小型智能车雷达回波样本样例




图 10 接收机噪声样本样例




图 9 行人雷达回波样本样例

图 7~10 分别展示了无人机、智能车、行人和接收机噪声样本的样例，其中横坐标轴均表示雷达同一距离门的多普勒维点数，纵坐标轴均表示信号幅值的大小。以雷达系统采样之后得到的 IQ 正交两路信号作为样本特征的两个维度，以长度固定的规格为 300×2 的数字序列形式进行存储。使用上述样本集来制作数据集，构建的样本尺寸为 $(300, 2)$ ，共得到 8 000 个样本。为增加样本数量可尝试对数据样本进行切割，再将其分割成 3 个尺寸为 $(100, 2)$ 的小样本输入到识别网络中，分割后样本的两个维度为归一化处理后雷达系统采样得到的 IQ 正交两路信号。这样得到的数据集总样本量为 24 000 个，共分为智能车、行人、无人机、噪声 4 类，每类的样本各有 6 000 个。将样本集按照 $6 : 2 : 2$ 的比例划分为训练集、验证集和测试集三部分，如表 1 所示。

表 1 数据集的划分

	训练集样本数/个	验证集样本数/个	测试集样本数/个
智能车	3 600	1 200	1 200
行人	3 600	1 200	1 200
无人机	3 600	1 200	1 200
噪声	3 600	1 200	1 200

3 个数据集之间相互独立，样本之间无重复性。

3.2 模型训练

模型的训练在单 GPU 上进行，GPU 型号为 NVIDIA

GeForce GTX 1080, 基于 Python 编程环境在 TensorFlow 框架下调用 LSTM 单元搭建循环神经网络。训练过程设置每次迭代的 batch_size=256, 迭代次数 epoch=200。网络训练过程如下:

1) 初始化网络结构和参数。使用 Adam 优化器进行优化, 将初始学习率 l_r 设置为 0.002。设置学习率衰减机制, 以验证集的准确率为参考, 若准确率在十次迭代后没有得到优化, 则将当前学习率乘以衰减系数得到新的学习率, 衰减系数设为 0.95。

2) 正向传播。从训练数据集中随机抽取样本输入网络, 计算各层 LSTM 网络的输出, 输出样本的类别预测概率。

3) 反向传播。计算并记录每次迭代之后训练集和验证集之间的误差, 计算损失函数并通过梯度下降的方法来优化更新网络参数。

4) 进行迭代训练, 不断优化网络模型。设置训练停止条件, 以验证集的损失函数值为标准, 判断是否继续进行训练, 若在任意十次迭代后损失函数值没有得到优化则停止训练。

3.3 结果分析

使用处理好的样本集在网络模型上进行训练, 训练集中每类样本各 3 600 个, 总数为 14 400 个, 当满足停止训练条件时则结束网络训练过程。定义识别准确率如下:

$$\text{识别准确率} = \frac{P_{\text{true}}}{P_n} \quad (12)$$

其中: P_{true} 表示被正确分类的样本数, P_n 表示总样本数。记录训练过程中训练集和验证集的识别准确率以及损失函数值, 其结果如图 11 和 12 所示。

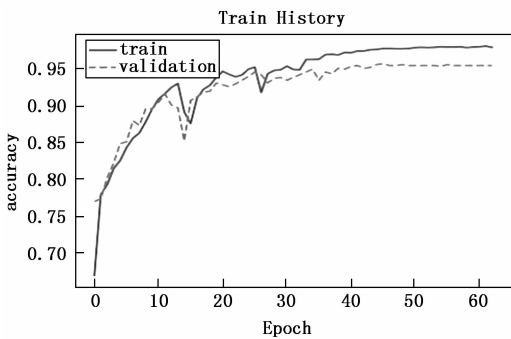


图 11 训练与验证过程识别准确率变化

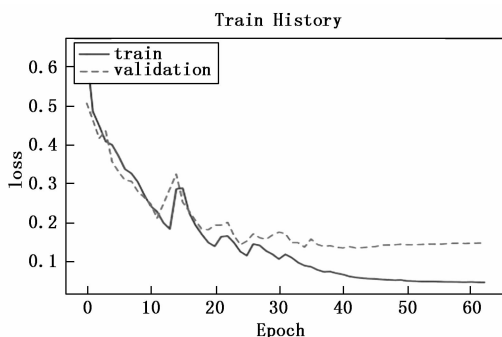


图 12 训练与验证过程损失函数值变化

图 11 和图 12 展示了训练过程中识别准确率与损失函数值的变化, 可以看到模型在第 63 次迭代后达到收敛并停止了训练, 最终得到的模型在验证集上的识别准确率达到 96%, 且未发生欠拟合或者过拟合现象。使用传统恒虚警检测方法与传统恒虚警检测方法与基于卷积神经网络的雷达目标识别模型在同样数据集上进行对比试验, 训练结果及得到的模型大小分别如表 2、表 3 所示。

表 2 不同雷达目标识别方法准确率对比

识别算法	传统恒虚警	卷积神经网络模型	残差连接 LSTM 模型
准确率	0.84	0.92	0.96

表 3 不同雷达目标识别方法模型大小对比

识别算法	卷积神经网络模型	残差连接 LSTM 模型
模型大小	14 M	5 M
网络参数个数	7 214 020	643 060

由表 2 可知残差连接 LSTM 模型在处理多类别目标识别问题上相比于传统恒虚警检测方法具有更高的识别准确率, 与卷积神经网络模型相比识别准确率相当甚至较优。结合表 2 与表 3 来看, 残差连接 LSTM 模型的模型相较于卷积神经网络模型规模更小且参数个数更少, 这是由于循环神经网络对于雷达回波数据的时序特性更为敏感, 因此也可以达到与网络模型更为复杂的基于卷积神经网络的目标识别模型水平相当的识别准确率。相较于卷积神经网络模型来说具有模型更小参数更少的优势。

使用测试集对传统恒虚警算法、训练好的卷积神经网络模型以及训练好的残差连接 LSTM 模型分别进行测试, 评估其具体的多类别目标识别性能并进行对比。测试集中各类样本的数量各有 1 200 个, 总计有 4 800 个。通过混淆矩阵来展示预测结果, 测试结果如图 13~15 所示。

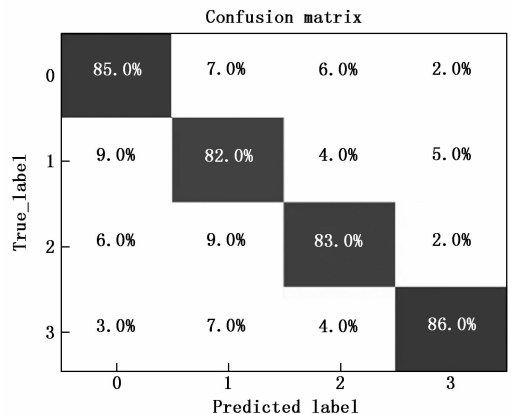


图 13 恒虚警算法预测结果

其中纵坐标轴均表示样本真实类型, 横坐标轴均表示对样本的预测类型, 由图 13~图 15 可以看出, 在与训练集和验证集都独立的测试集测试下, 传统的恒虚警算法对于无人机、行人、智能车等类别目标的识别准确率分别仅有




图 14 卷积神经网络模型预测结果




图 15 残差连接 LSTM 模型预测结果

85%、82%和 83%；卷积神经网络模型对于无人机、行人、智能车等类别目标的识别准确率分别为 95%、93%和 93%；而基于残差连接的 LSTM 的雷达目标识别模型对于无人机、行人、智能车等多类别目标的识别准确率则分别达到了 97%、94%和 96%。对于无人机目标的识别准确率高约 3%的原因主要在于采样时，无人机的运动过程及飞行状态较为规律，因此其样本特征较为规则；而不同行人的动作与行为的变化较大，较为不规律，因此样本特征相对来说复杂一些，可能会导致识别效果稍差。依据测试得到的混淆矩阵分别计算 3 种算法的 F_1 值，如表 4 所示。

表 4 不同算法 F_1 值对比

	无人机	行人	智能车	噪声
传统恒虚警	0.84	0.80	0.84	0.88
卷积神经网络模型	0.95	0.93	0.92	0.92
残差连接 LSTM	0.97	0.93	0.95	0.98

由表 4 可以看出，基于残差连接 LSTM 的雷达目标识别模型对于目标的分类预测效果明显优于传统恒虚警算法；与卷积神经网络模型相比效果相近，但基于残差连接

LSTM 的识别模型网络规模要更小一些，在训练和使用上能够更为方便。实验证明基于残差连接 LSTM 的雷达目标识别模型的识别性能比传统恒虚警算法更好，且能在模型规模更小的情况下达到与卷积神经网络模型相当的识别效果。

4 结束语

针对传统雷达目标识别方法在实际应用中面临环境噪声复杂且目标回波信号弱的情景时，无法高效地完成对无人机、智能车、行人等小型目标检测任务的问题，考虑使用深度学习方法来解决。针对卷积神经网络模型网络结构相对复杂且对雷达回波数据的时序特性不敏感的情况，考虑到循环神经网络善于分析序列数据的特性，以雷达多普勒维的回波序列构建数据集，提出一种基于残差连接 LSTM 网络的雷达目标分类识别方法，通过训练残差连接 LSTM 网络来提高对多种类目标的识别准确率。实验证明，基于残差连接 LSTM 的雷达目标识别模型相较于卷积神经网络模型参数更少规模更小，且能够在对无人机、智能车、行人和噪声等四种目标的识别与分类中达到水平相当的效果，与传统恒虚警检测算法相比得到了更好的识别准确率和 F_1 值，比传统恒虚警算法的识别效果更好。

参考文献：

- [1] 南京电子技术研究所译. 雷达手册 3 版 [M]. 北京：电子工业出版社，2010.
- [2] MAHAFAZA B R, WINTON S C, et al. Handbook of radar signal analysis [M]. CRC Press, 2021.
- [3] FINN H M, JOHNSON R S. Adaptive detection mode with threshold control as a function of spatially sampled clutter level estimates [J]. RCA Review, 1968, 29 (9): 414-464.
- [4] 邹成晓, 张海霞, 程玉堃. 雷达恒虚警率检测算法综述 [J]. 雷达与对抗, 2021, 41 (2): 29-35.
- [5] MOHAMED B, SOLTANI F. Performance analysis of mean level constant false alarm rate detectors with binary integration in Weribullbackground [J]. IET Radar Sonar Navigation, 2015, 9 (3): 233-240.
- [6] 魏志强, 毕海霞, 刘霞. 基于深度卷积神经网络的图上半监督极化 SAR 图像分类算法 [J]. 电子学报, 2020, 48 (1): 66-74.
- [7] LIU C L, FU S W, LI Y J, et al. Multichannel speech enhancement by raw waveform-mapping using fully convolutional networks [J]. IEEE/ACM Transactions on Audio, Speech, and Language Processing, 2020, 28: 1888-1900.
- [8] 韩子硕, 王春平, 付强. 基于深层次特征增强网络的 SAR 图像舰船检测 [J]. 北京理工大学学报, 2021, 41 (9): 1006-1014.
- [9] HE C, TU M X, XIONG D H, et al. A component-based multi-layer parallel network for airplane detection in SAR imagery [J]. Remote Sensing, 2018, 10 (7): 1016.

- [10] KANG M, JI K F, LENG X G, et al. Contextual region-based convolutional neural network with multilayer fusion for SAR ship detection [J]. *Remote Sensing*, 2017, 9 (8): 860.
- [11] FARLNA A, STUDER F A. 雷达数据处理 (第一卷) [M]. 匡永胜, 译. 北京: 国防工业出版社, 1988.
- [12] 沈梦启. 基于卷积-循环神经网络的雷达高分辨距离像目标识别方法研究 [D]. 西安: 西安电子科技大学, 2019.
- [13] 杨星鑫, 吕泽均. 基于 LSTM 的无人机轨迹识别技术研究 [J]. *现代计算机*, 2020 (5): 18-22, 25.
- [14] 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.
- [15] WANG J, ZHENG T, LEI P, et al. Hand gesture recognition method by radar based on convolutional neural network [J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2018, 44 (6): 1117-1123.
- [16] HU Y, LIU Y, LV S, et al. DCCRN: Deep complex convolution recurrent network for phase-aware speech enhancement [C] // *Annual Conference of the International Speech Communication Association 2020*, 2020: 1-5.
- [17] WANG H M, WANG D L. Time-frequency loss for CNN based speech super-resolution [C] // *ICASSP 2020 - 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE, 2020: 861-865.
- [18] 靳 标, 彭 宇, 邝晓飞, 等. 基于串联式一维神经网络的毫米波雷达动态手势识别方法 [J]. *电子与信息学报*, 2021, 43 (9): 2743-2750.
- [19] WENINGER F, ERDOGAN H, WATANABE S, et al. Speech enhancement with LSTM recurrent neural networks and its application to noise-robust ASR [C] // *International conference on latent variable analysis and signal separation*, Springer, Cham, 2015: 91-99.
- [20] 畅 鑫, 李艳斌, 田 森, 等. 基于一维卷积循环神经网络的深度强化学习算法 [J]. *计算机测量与控制*, 2022, 30 (1): 258-265.
- [21] WÖLLMER M, ZHANG Z X, WENINGER F, et al. Feature enhancement by bidirectional LSTM networks for conversational speech recognition in highly non-stationary noise [C] // *2013 IEEE International Conference on Acoustics, Speech and Signal Processing*. Vancouver, BC, Canada. IEEE, 2013: 6822-6826.
- [22] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. *Neural Computation*, 1997, 9 (8): 1735-1780.
- [23] LIN J, GAN C, HAN S. TSM: Temporal shift module for efficient video understanding [C] // *2019IEEE/CVF International Conference on Computer Vision*, Seoul, Korea (South), 2019: 7082-7092.
- [24] 郭佳丽, 邢双云, 栾 昊, 等. 基于改进的 LSTM 算法的时间序列流量预测 [J]. *南京信息工程大学学报 (自然科学版)*, 2021, 13 (5): 571-575.
- [25] 张 帆, 张 良, 刘 星, 等. 基于深度残差网络的脱机手写汉字识别研究 [J]. *计算机测量与控制*, 2017, 25 (12): 259-262.
- [26] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016: 770-778.
- [27] KAMALEDIN G S. Competitive cross-entropy loss: a study on training single-layer neural networks for solving nonlinearly separable classification problems [J]. *Neural Processing Letters*, 2018, 50 (2): 1-8.
- [4] 赵 晓, 王 铮, 黄程侃, 等. 基于改进 A* 算法的机器人路径规划 [J]. *机器人*, 2018, 40 (6): 903-910.
- [5] 贾 全, 张小超, 苑严伟, 等. 拖拉机自动驾驶系统上线轨迹规划方法 [J]. *农业机械学报*, 2018, 49 (4): 36-44.
- [6] 赵 晓, 王 铮, 黄程侃, 等. 基于改进 A* 算法的机器人路径规划 [J]. *机器人*, 2018, 40 (6): 903-910.
- [7] QING G, ZHENG Z, YUE X. Path-planning of automated guided vehicle based on improved Dijkstra algorithm [C] // *29th Chinese Control and Decision Conference (CCDC)*, Chongqing: IEEE, 2017: 7138-7143.
- [8] 张 毅, 代恩灿, 罗 元. 基于改进遗传算法的机器人路径规划 [J]. *计算机测量与控制*, 2016, 24 (1): 313-316.
- [9] ZHANG L, ZHANG Y, LI Y. Mobile robot path planning based on improved localized particleswarm optimization [J]. *Sensors Journal*, 2021, 21 (5): 6962-6972.
- [10] MA L, XUE J, KAWABATA K, et al. Efficient sampling-based motion planning for on-road autonomous driving [J]. *Transactions on Intelligent Transportation Systems*, 2015, 16 (4): 1961-1976.
- [11] RASTELLI J P, LATTARULO R, NASHASHIBI F. Dynamic trajectory generation using continuous-curvature algorithms for door to door assistance vehicles [C] // *Intelligent Vehicles Symposium*, Dearborn: IEEE, 2014: 510-515.
- [12] 黄 辰, 费继友, 刘 洋, 等. 基于动态反馈 A* 蚁群算法的平滑路径规划方法 [J]. *农业机械学报*, 2017, 48 (4): 34-40, 102.
- [13] 强 宁, 高 洁, 康凤举. 基于 PSO 和 3 次样条插值的多机器人全局路径规划 [J]. *系统仿真学报*, 2017, 29 (7): 1397-1404.
- [14] GALLINA P, GASPARETTO A. A technique to analytically formulate and to solve the 2-dimensional constrained trajectory planning problem for a mobile robot [J]. *Journal of Intelligent & Robotic Systems*, 2000, 27 (3): 237-262.
- [15] 方忆湘, 刘文学. 基于几何特性的 3 次均匀 B 样条曲线构造描述 [J]. *工程图学学报*, 2006 (2): 96-102.

████████████████████
 (上接第 181 页)