

doi: 10.7690/bgzdh.2022.08.011

# 基于 MCNN-GRU 的舰面目标碰撞预警方法

汪 丁<sup>1</sup>, 黄 葵<sup>1</sup>, 朱兴动<sup>2</sup>, 范加利<sup>1</sup>, 王 正<sup>1</sup>

(1. 海军航空大学青岛校区, 山东 青岛 266041; 2. 海军航空大学, 山东 烟台 264001)

**摘要:** 为提升甲板舰面目标的转运安全性, 提出一种多个 CNN-GRU (multiple CNN-GRU, MCNN-GRU) 碰撞预警网络模型。该网络融合了卷积神经网络(convolutional neural network, CNN)对单时间步信息特征的提取能力以及门控循环单元(gate recurrent unit, GRU)对时序序列的记忆能力, 通过多通道网络结构提升对多时间步信息特征的处理性能; 在数据集上, 利用目标检测网络和关键点检测网络、位姿解算模型及碰撞检测方法制作舰面目标碰撞预警数据集。通过不同网络在数据集上进行实验的结果表明: 该模型对舰面目标的双机碰撞预警精度为 92.44%, 具有较好的效果。

**关键词:** 卷积神经网络; 门控循环单元; 碰撞预警; 循环神经网络; 舰面目标**中图分类号:** TJ83   **文献标志码:** A

## Ship Surface Target Collision Warning Method Based on MCNN-GRU

Wang Ding<sup>1</sup>, Huang Kui<sup>1</sup>, Zhu Xingdong<sup>2</sup>, Fan Jiali<sup>1</sup>, Wang Zheng<sup>1</sup>

(1. Qingdao Campus, Naval Aviation University, Qingdao 266041, China;

2. Naval Aviation University, Yantai 264001, China)

**Abstract:** A multiple CNN-GRU (MCNN-GRU) collision warning network model is proposed to improve the transfer safety of ship surface targets. The network combines the feature extraction ability of convolutional neural network (CNN) for single time step information and the memory ability of gated recurrent unit (GRU) for time sequence. Multi-channel network structure is used to improve the processing performance of multi-time step information features. Target detection network, key point detection network, pose calculation model and collision detection method are used to produce ship surface target collision warning data set. The experimental results on different network data sets show that the collision warning accuracy of the model is 92.44%, and it has a good effect.

**Keywords:** convolutional neural network; gated recurrent unit; collision warning; recurrent neural network; ship surface target

## 0 引言

大型舰船的作业空间十分有限。针对有限空间的快速保障技术, 可为提升飞机出动率等提供有力支撑, 也是舰载技术未来发展方向之一<sup>[1]</sup>。在保障作业中, 除了飞机起降之外, 转运作业同样具有较大风险, 需要各岗位密切高效的配合。在甲板作业有严格流程和规范的情况下, 作业过程中依旧会有人为或环境等因素的干扰, 从而导致不安全因素的增加<sup>[2]</sup>。根据美国海军的统计数据, 从 1980 到 2008 年间有 35 名舰员在飞行甲板作业中死亡<sup>[3]</sup>。因此, 研究碰撞预警对预防转运过程中的碰撞事故具有重要意义。

运动目标的碰撞预警已有广泛研究, 尤其在船舶避碰和无人驾驶车辆安全系统上有了相关技术应用。文献[4]开发了一种针对没有船舶自动识别系统(automatic identification system, AIS)的小型渔船碰

撞预警算法, 从小型渔船上自动发送船舶位置的 Vpass 设备生成的导航数据库中提取案例, 实现了在危险情况下连续触发报警。文献[5]提出了一种基于单目视觉的带距离预测的前向碰撞预警系统, 使用 YOLO 算法检测前方车辆, 卡尔曼滤波和匈牙利算法实现跟踪和 ID 切换, 并通过逆透视映射(inverse perspective mapping, IPM)为鸟瞰图来计算车辆之间的距离。文献[6]将海域划分为网格, 利用船舶的位置、速度和方向关系等关键要素计算网格状态, 利用马尔科夫链建立状态转移矩阵从而实现目标位置预测, 但转移矩阵难以应对复杂的轨迹变化。文献[7]提出了在机场环境下的摄像测量方案, 针对场景单一、大视场的机场环境, 采取多个控制点实现外参的标定以及目标位置的测量, 实现了机场调运系统避碰辅助设施中的目标飞机的测量定位, 但没有对过近预警开展研究。文献[8]从 2016

收稿日期: 2022-04-20; 修回日期: 2022-05-28

基金项目: 军内科研基金

作者简介: 汪 丁(1997—), 男, 湖南人, 硕士, 从事计算机视觉研究。E-mail: 978032666@qq.com。

年上海虹桥机场航班碰撞事故的教训出发, 针对国内机场地图和航班难以统一的情况, 以民航飞机的广播式自动相关监视系统 (automatic dependent surveillance-broadcast, ADS-B) 为数据入口, 可用于民航机场跑道避碰算法验证和演示。

碰撞预警按照范围大致可以分为单个目标预警和区域目标预警, 单个目标预警如文献[4]和[5]所示, 通常将预警设备直接安装在目标上, 通过相互距离来进行预警; 区域目标预警如文献[6]和[7]所示, 通过摄像头或者定位终端等获取区域内所有目标位置, 然后计算碰撞风险从而进行预警。基于区域的碰撞预警方法大体上可分为基于轨迹的碰撞预警和基于状态的碰撞预警。基于状态的碰撞预警是通过统计碰撞事件前后目标间的空间位置关系来拟合基于经验的碰撞危险度模型, 然后将各类定位方式获取的目标位置输入模型来计算危险度<sup>[9]</sup>。

笔者通过建立舰面目标碰撞数据集对提出的碰撞预警算法进行训练, 得到碰撞预警模型。然后通过目标的实时位置和运动特征来判断当前目标的危险度进行预警, 从而实现危险状态预警。

## 1 相关知识

### 1.1 CNN 卷积网络

卷积神经网络 (CNN) 包括卷积层、池化层和全连接层 3 个主要部分, 常用于数据特征提取和图像分类任务<sup>[10]</sup>。卷积神经网络是通过模拟人脑视觉系统, 采用卷积层和池化层依次交替的网络结构, 在减少数据量的同时提取出更多有效信息, 同时参数减少和权值共享使得训练中能够加速收敛。在卷积层中, 每个单元与上层网络的局部感受域连接, 利用卷积核来提取数据特征; 在激活层中, 通过激活不同的激励函数实现非线性变换, 来保证神经模型的拟合能力; 在池化层中, 可以在提取数据特征的同时减少数据量, 用最小的空间来保留数据特征。最后通过全连接层将提取的特征图映射成为一个固定长度的特征向量进行分类或回归计算。相比于反向传播(back propagation, BP) 网络<sup>[11]</sup>, CNN 网络可以更好地通过卷积层中的卷积运算和池化层的降采样来提取数据的潜在特征, 具有全局感知能力和参数共享的优势, 可以实现对高维数据的处理<sup>[12]</sup>。

### 1.2 循环神经网络

传统网络结构多是层与层之间的联系, 在处理分类问题上具有较好的表现, 但对于序列问题的处

理却是低效的<sup>[13]</sup>。循环神经网络 (recurrent neural network, RNN) 是一类用于处理时序数据的神经网络, 在处理当前数据的同时保留历史数据的特征, 能够有效保留数据的时序特征<sup>[14]</sup>。RNN 网络的基本原理是将神经元的输出再接回神经元的输入, 从而保证神经网络具有一定的记忆能力, 其神经元结构如图 1 所示。图中:  $X$  表示网络的输入,  $O$  是网络的输出,  $U$ 、 $V$ 、 $W$  分别表示网络的神经参数,  $S$  表示网络的隐藏状态。

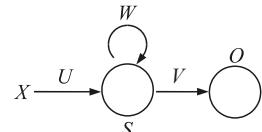
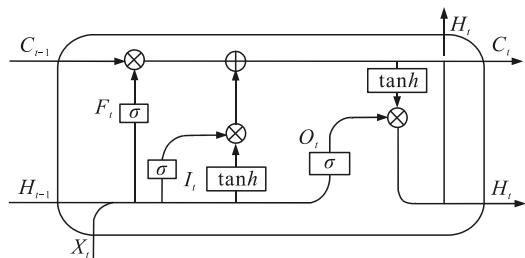
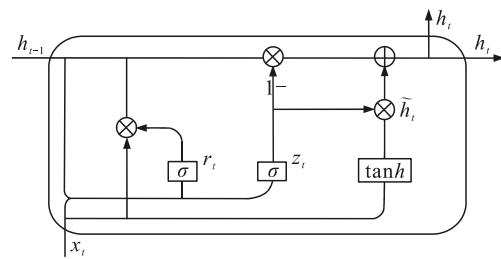


图 1 RNN 单元

RNN 网络虽然在时序处理上有一定优势, 但由于在反向传播中, 残差经过层层累积, 长时序问题中的梯度消失或者梯度爆炸限制了其无法学习到连接较远神经元的信息。针对 RNN 长期依赖的问题, 存有一种特殊的循环神经网络, 即长短时记忆网络 (long short term memory, LSTM)。如图 2(a)所示, LSTM 网络是一种特殊的循环网络, 能够有效解决 RNN 网络出现梯度消失或者梯度爆炸的问题, 使得神经网络具有记忆功能。门控循环单元 (GRU)<sup>[15]</sup> 是 2014 年提出的一种 LSTM 变体, GRU 使得每个循环单元可以自适应地捕捉不同时间刻度下的依赖。如图 2(b)所示, 与 LSTM 单元相似, GRU 具有调节信息流动的门单元<sup>[16]</sup>, 但其结构相对简单, 模型参数少, 收敛和权值更新的效率更高, 实验表明其效果更好。



(a) 长短时记忆网络单元



(b) 门控循环单元

图 2 2 种循环神经网络单元对比

GRU 单元具有 2 个门控函数：1) 更新门，主要用于控制前一时刻的状态信息对当前状态的影响程度；2) 重置门，主要控制前一时刻的状态信息对当前状态候选集的影响程度<sup>[17]</sup>。计算公式如下：

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t]); \quad (1)$$

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t]); \quad (2)$$

$$\tilde{h}_t = \tan h(W_h \cdot [r_t \times h_{t-1}, x_t]); \quad (3)$$

$$h_t = z_t \odot \tilde{h}_t + (1 - z_t) \times h_{t-1}. \quad (4)$$

式中： $W_r$ 、 $W_z$ 、 $W_h$  为权重参数； $r_t$  和  $z_t$  分别为重置门和更新门； $x_t$  和  $h_{t-1}$  为当前状态和前一时间步输入的状态信息； $\tilde{h}_t$  为当前时间步的信息候选集状态；

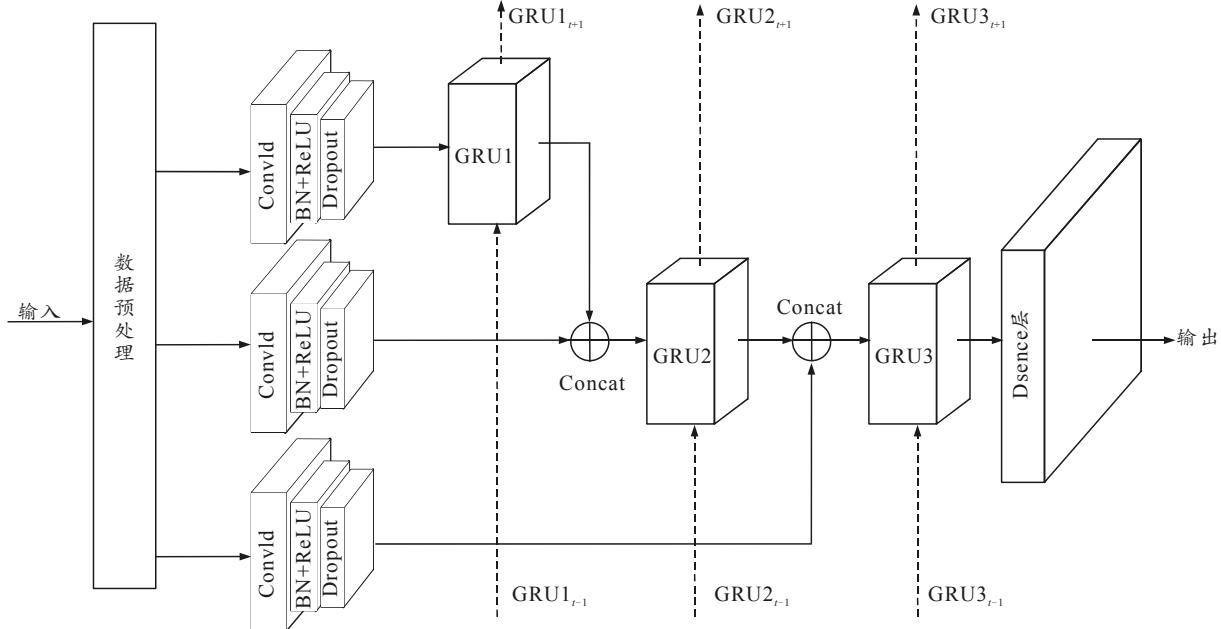


图 3 MCNN-GRU 模型

MCNN-GRU 网络模型充分利用了 CNN 网络和 GRU 网络的优点，CNN 网络负责数据的特征提取，GRU 网络负责学习时间序列的长期依赖<sup>[18]</sup>。通过组合 2 个网络，使其既能学习时序数据的变化趋势，又能提取每个时间的数据特征，实现较好的分类效果。同时，神经元之间的连接是多维的，在时间维度和空间维度上都进行了连接；因此，可以同时将上一层网络的输出和上一时刻网络的输出  $GRU1_{t-1}$ 、 $GRU2_{t-1}$ 、 $GRU3_{t-1}$  应用到当前的计算中。

MCNN-GRU 网络模型作为一种端对端的模型，直接利用历史帧和当前帧的特征信息来实现图像帧的预警状态判别。在输入模块中，将一帧图像区域内的目标两两匹配形成一组碰撞预警检测对象，将每 2 个目标信息  $S=\{w_1, w_2, \dots, w_{15}\}$  映射成一个长度为 30 的 1 维向量，并进行数据正则化处理，

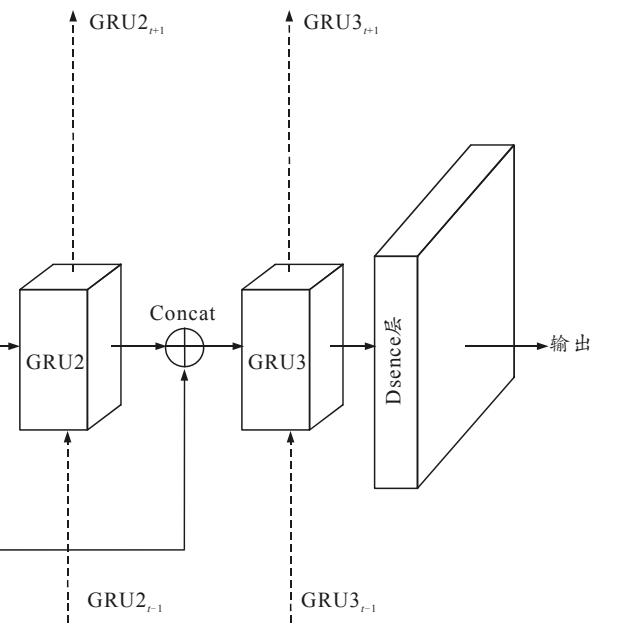
$h_t$  为当前单元输出的状态信息。

## 2 基于 MCNN-GRU 的预警方法

### 2.1 MCNN-GRU 模型

碰撞预警状态分类预测难度要远高于普通的分类问题，因为舰面目标前后时间步的运动轨迹在数据特征上没有明显区分，单一模型效果十分有限，需要通过融合目标状态特征和目标的时序特征才能实现较好的状态分类。

笔者提出多个 CNN-GRU (MCNN-GRU) 模型，主要包括输入层、CNN 模块和 GRU 模块以及输出层，其网络总体结构如图 3 所示。



实现数据的预处理，然后输出到 3 个不同大小卷积核的卷积网络中。

在卷积模块中，由一个 1 维卷积层、一个 Batch Normalization 层、一个激活函数以及一个 Dropout 层组成一个卷积模块。3 个 Conv1d 网络的卷积核大小分别设置为 11、13、15，每个卷积层的输入向量长度为  $30 \times 3$ ，输出通道数为 16。卷积网络将输入的 1 维向量数据进行卷积操作，利用 ReLU 激活函数进行激活，并加入 Dropout 层防止出现过拟合。卷积输出的特征与上一时刻的记忆特征将一同送入到 GRU 模块中。

GRU 模块由 3 个 GRU 层和 2 个 Contact 模块组成，每个 GRU 层设置 16 个门控循环单元，时间步设置为 10，并设置激活函数为 SoftSign。GRU 模块将上一时间的状态信息和当前时刻的状态信息融

合后送入到更新门和重置门中，经过激活函数后得到更新和重置的控制量。重置门将控制上一个状态信息  $h_{t-1}$  的进入量，并与当前状态信息  $x_t$  一起形成候选集  $\tilde{h}_t$ 。而更新门将控制  $\tilde{h}_t$  以及  $h_{t-1}$  写入到当前时刻输出状态量  $h_t$  的大小。GRU 模块输出的同样分为 2 部分：1) 作为下一个时刻的  $h_{t+1}$ ；2) 分将通过 Concatenate 函数与下一层 CNN 网络输出的特征信息相连接。其余 GRU 模块中进行同样的操作和处理，从而在保留各部分特征的情况下实现多尺度数据特征的融合。

在输出模块中，隐藏层为 100，输出层为 3，设置激活函数为 SoftMax。经过输出模块，可以得到当前图像帧的预警状态。

## 2.2 舰面目标碰撞预警数据

相比于常见分类问题的数据集，碰撞数据集的采集难度较大，网络上也鲜有相关数据。尤其是针对舰面目标的碰撞，目前数据非常有限且获取难度较大。为实现碰撞预警数据的有效采集，针对舰面

环境搭建了等比缩放模型，通过调整相机视角以及建立模型比例关系等，尽可能逼近真实有效的碰撞，以在实验室条件下实现碰撞数据的采集与数据集制作。之后经过迁移学习和算法训练后，便可以辅助实现真实环境的碰撞预警。

由于目标的不规则外形边界以及甲板狭窄的活动空间，仅依靠目标检测的方框来描述目标轮廓信息无法达到实际要求的精度，在安全距离时同样容易出现误报警，所以需要更加精确的目标轮廓点坐标来判断两者的安全状态。根据舰面目标的特点，开发了舰面目标碰撞数据集制作工具。该工具以多个神经网络模块作为基础，通过对双方目标轮廓关键点进行碰撞检测来判断是否发生碰撞，并设定当前时间步为碰撞状态，碰撞前  $N$  个时间步为危险状态，其余状态为安全状态，提前预警的时间步大小可以根据实际的需求进行调整，笔者设置为 5 个时间步。工具可以实现自动或者单步运行，以实现高效的碰撞数据采集与制作，具体的流程如图 4 所示。

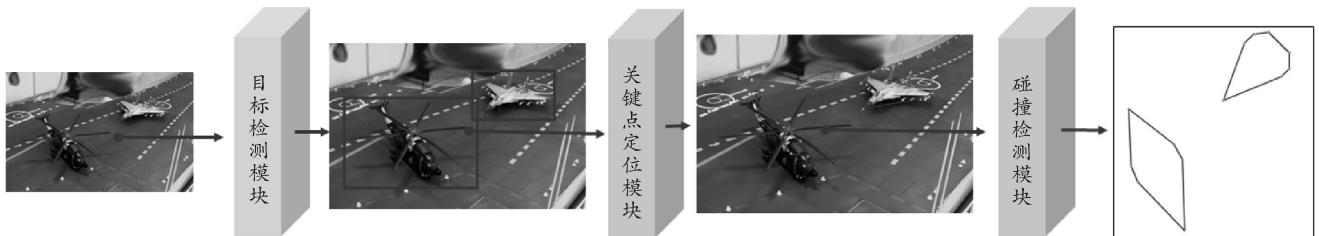


图 4 碰撞预警数据集制作流程

碰撞数据集制作工具由目标检测模块、关键点检测模块、关键点定位模块以及碰撞检测模块等组成。其中：目标检测模块可以实现对不同类型目标的识别和框选；关键点定位模块将会根据目标检测的结果对目标的轮廓关键点进行检测和位姿解算，以实现图像的矫正以及像素坐标到舰面目标平面坐标的转换；碰撞检测模块将会根据平面上各舰面目标的点位关系来判别当前舰面的安全状态。

在舰面目标碰撞数据集中，设置 3 类预警状态标志位：0 表示安全，1 表示危险，2 表示碰撞。如图 5 所示，在一组时间序列中，将会通过目标之间产生实际碰撞状态设置为 2，碰撞状态前 5 帧图像状态设置为 1，其余状态设置为 0。



图 5 预警状态标签设定

在数据集的格式中，将每一个时间步的目标状

态信息表示为一组长度为 34 位的向量，以序列  $A$  为例，具体如表 1 所示

表 1 数据集格式

字段名	序号
帧序号	$A_1$
目标 1 ID	$A_2$
目标 1 关键点 1~7	$A_3 \sim A_{16}$
目标 1 航向	$A_{17}$
目标 2 ID	$A_{18}$
目标 2 关键点 1~7	$A_{19} \sim A_{32}$
目标 2 航向	$A_{33}$
预警状态	$A_{34}$

为充分利用时序数据的特征，需要针对输入的帧特征数据进行预处理。如图 6 所示，根据序列关系，将连续 3 帧的特征数据连接起来作为数据的输入，将第 3 帧的标签作为新序列的标签。

## 3 实验结果

### 3.1 实验环境

在实验中，将训练优化器设置为 Adam，迭代

轮数为 100 轮, Batchsize 为 16, 共采集数据 5 000 条, 训练集、验证集以及测试集的比例为 6:2:2, 实验具体环境配置如表 2 所示。

表 2 实验环境

参数	配置信息
CPU	Intel Xeon Silver 4110
内存	32 G
GPU	NVIDIA 2080Ti
显存	16 G
系统	Ubuntu16.04
深度学习框架	TensorFlow1.14
加速环境	CUDA9.0, CUDNN7.0

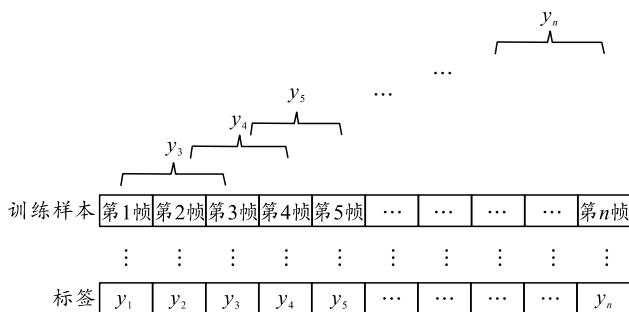


图 6 数据预处理方法

在实验环境配置上, 采用 2 架舰载机与一架直升机进行模拟, 将直升机和一架舰载机放置于甲板平面停机位, 利用细绳牵引另一架舰载机运动, 来开展碰撞预警实验。

### 3.2 评价指标

为评价网络的有效性, 采用准确率(Acc)、精确率(Precision)、召回率(Recall)以及  $F_1$  值作为实验的评价标准。其中: 真正样本(true positive, TP)表示检测到的目标类别与真实目标类别一致的样本数量; 真负样本(true negative, TN)表示模型预测为负的负样本; 假正样本(false positive, FP)表示检测到的目标类别与真实目标类别不一致的样本数量; 假负样本(false negative, FN)表示真实存在但未被网络检测出的样本数量。

1) 准确率是分类正确的样本占总样本的比重, 计算公式为:

$$\text{Acc} = (\text{TP} + \text{TN}) / (\text{TP} + \text{TN} + \text{FP} + \text{FN})。 \quad (5)$$

2) 精确率是正确预测的样本占所有预测类别正确样本的比重, 计算公式为:

$$\text{Precision} = \text{TP} / (\text{TP} + \text{FP})。 \quad (6)$$

3) 召回率是正确预测的样本占所有真实类别正确样本的比重, 计算公式为:

$$\text{Recall} = \text{TP} / (\text{TP} + \text{FN})。 \quad (7)$$

4) 评价一个模型不仅要看准确率还要看召回

率, 且训练样本很不平衡时,  $F_1$  评价效果更好<sup>[19]</sup>。 $F_1$  计算公式为:

$$F_1 = 2 / (1/\text{Precise} + 1/\text{Recall})。 \quad (8)$$

5) FPS(frames per second)用来描述每秒钟处理的时间步数据。

### 3.3 实验结果与分析

为更好地评估算法性能, 分别使用 BP 网络、CNN 网络、GRU 网络、CNN+GRU 网络及 GRU+CNN 网络作为对比实验, 测试结果如表 3 所示, 各网络的 loss 曲线如图 7 所示。

表 3 不同模型对比

模型	Acc	Precision	Recall	$F_1$	Fps
BP 网络	0.711 4	0.828 5	0.640 5	0.722 4	180.0
CNN 网络	0.812 7	0.820 1	0.796 5	0.808 1	92.0
GRU 网络	0.841 4	0.855 2	0.829 6	0.842 2	29.1
CNN+GRU 网络	0.865 7	0.871 4	0.859 0	0.865 1	63.0
GRU+CNN 网络	0.825 7	0.844 8	0.808 2	0.826 0	37.0
MCNN-GRU 网络(本文中)	0.924 4	0.929 8	0.918 7	0.924 2	28.5

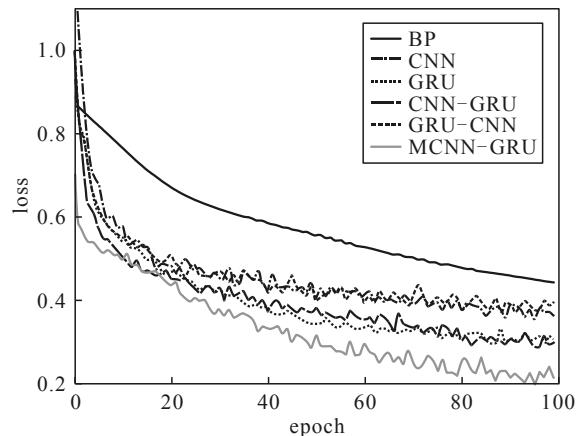


图 7 损失曲线对比

首先分析 BP 网络在数据集上的性能, 可以看出 BP 网络在实时性上较为突出, 但收敛速度和准确率相差较多, 表明简单的 BP 网络无法达到预期目标。

为分析 2 种网络模型在数据集上的效果差异, 分别利用多层 CNN 网络和 GRU 网络进行测试, CNN 网络相比 GRU 网络结构简单, 因而实时性较好, 但在精度和收敛速度上不如 GRU 网络, 从实验效果可以看出 2 种模型各有优劣。

为分析 2 种网络模型在空间顺序上带来的效果差异, 设计了单层 CNN+GRU 网络和 GRU+CNN 网络对比实验。从实验结果可以看出, CNN 网络在头部时具有更高的准确率和速率, 表明在碰撞预警数

据集上先提取特征后利用特征进行预测更有优势。

在确定网络的组合顺序后,为进一步探究网络层数对模型性能的影响,将网络进行迭代组合并进行了实验比对,分析其对精确率和速率的影响。实验结果表明,随着网络层数增加模型准确率提升不断变慢,而速率的下降不断加快。如图8所示,在网络层数为3层时可以满足准确率和速率的实际需求。同时 $F_1$ 值与Acc基本上保持一致,表明数据集各样本分布符合规律和模型需求。

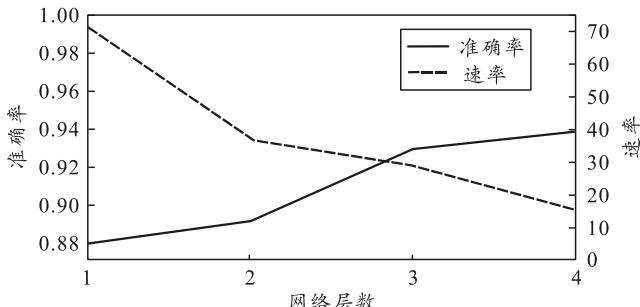


图8 准确率和速率随网络层数的变化

为对模型进一步优化,通过消融实验对模型不同参数下的性能进行测试。实验结果表明,准确率随卷积核大小的变化表现为波动;因此,设置最优3个结果为3个并行CNN网络的卷积核大小,如图9(a)所示。如图9(b)所示,在Batchsize的选择上,在大小为16时取得最好的效果,因此设置为16。

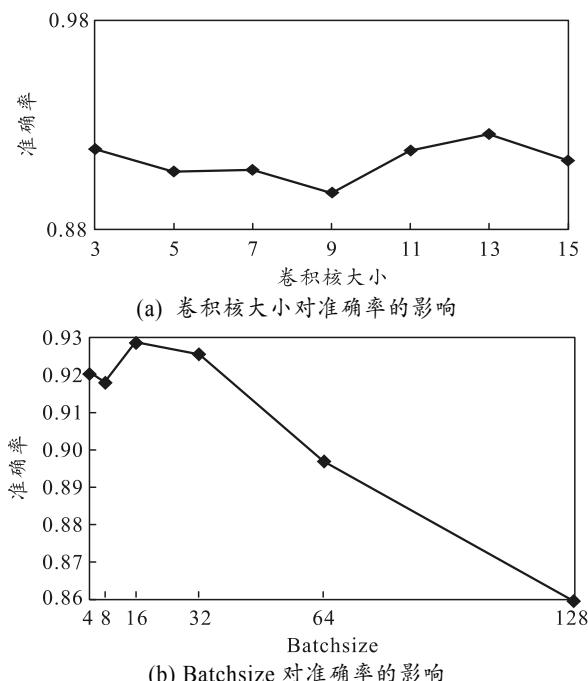


图9 模型消融实验

## 4 结论

笔者针对舰面目标的转运安全问题,融合CNN

网络和GRU网络提出了MCNN-GRU多通道网络模型,在利用目标检测、关键点检测与定位以及位姿解算等方法开发制作的舰面目标碰撞预警数据集上进行了测试,并对网络模型进一步优化。在满足实时性的前提下进行双机碰撞实验,利用舰面目标的位置和运动特征对当前危险状态的判别精度能够达到92.44%。实验结果表明:MCNN-GRU模型能够实现舰面目标碰撞前的预警,证明了该方法的有效性和可行性。

## 参考文献:

- [1] 王永庆. 固定翼舰载战斗机关键技术与未来发展[J]. 航空学报, 2021, 42(5): 1-15.
- [2] 陈成. 飞行甲板航空保障系统配置对出动架次率的影响研究[D]. 哈尔滨: 哈尔滨工程大学, 2018.
- [3] 胡容兵, 谢君, 傅冰. 飞行甲板安全评价指标体系研究[J]. 海军工程大学学报, 2013, 25(6): 93-98.
- [4] LEE M K, PARK Y S, PARK S, et al. Application of Collision Warning Algorithm Alarm in Fishing Vessel's Waterway[J]. Applied Sciences, 2021, 11(10): 4479.
- [5] VENKATESWARAN N, HANS W J, PADMAPRIYA N. Deep learning based robust forward collision warning system with range prediction[J]. Multimedia Tools and Applications, 2021(8): 1-19.
- [6] 任宇翔, 赵建森, 刘卫, 等. 基于AIS数据和LSTM网络的船舶航行动态预测[J]. 上海海事大学学报, 2019, 40(3): 32-37.
- [7] 赵哲. 机场调运系统避碰辅助设施中的摄像测量技术研究[D]. 长沙: 国防科学技术大学, 2014.
- [8] LIAO K, ZHAO Y, ZHANG X. A Simulation Platform for Airport Runway Collision Warning System[J]. Journal of Physics Conference Series, 2021, 1827(1): 012044.
- [9] WEN C, LIU S, YAO X, et al. A novel spatiotemporal convolutional long short-term neural network for air pollution prediction[J]. Science of the Total Environment, 2019, 654(1): 1091-1099.
- [10] HU W, HUANG Y Y, WEI L, et al. Deep Convolutional Neural Networks for Hyperspectral Image Classification[J]. Journal of Sensors, 2015(2): 1-12.
- [11] ZHANG S, LIU Z, SHEN F, et al. A prediction model of buses passenger flow based on neural networks[J]. Journal of Physics: Conference Series, 2020, 1656(1): 12002-12007.
- [12] 秦可. 基于优化神经网络模型的船舶航迹预报[D]. 大连: 大连海事大学, 2020.
- [13] KIM Y. "Convolutional neural networks for sentence classification," 2014, arXiv: 1408. 5882[R/OL]. Available: <http://arxiv.org/abs/1408.5882>.

(下转第80页)