

# 基于深度神经网络 AdaMod 优化模型的 来袭目标攻击意图识别

王家鑫<sup>1</sup>, 王瑞琪<sup>2</sup>, 孟海波<sup>2</sup>, 蒲红明<sup>2</sup>, 陈天群<sup>2</sup>

(1. 海装驻上海地区某部, 上海 201109; 2. 上海机电工程研究所, 上海 201109)

**摘要:** 海上舰艇防空反导作战基于目标攻击意图识别是现代舰艇防空技术的研究热点; 来袭目标攻击意图识别是战场态势分析的一个重要部分, 以往是通过先验知识和先验概率进行量化分析与明确攻击意图识别特征值的影响权重; 深度神经网络可通过自适应学习目标攻击意图的特征值, 可以在缺乏先验知识的条件下, 通过小样本集的目标攻击意图的特征值训练, 学习特征数据和攻击意图识别之间的对应关系与映射; 通过引入 GeLUs 激活函数和 AdaMod 优化算法加快模型收敛, 并解决了 Adam 模型可能无法收敛到最优解的问题; 实验结果显示文中提出的模型可以在先验知识不足及训练数据规模小的情况下, 有效识别来袭目标攻击意图, 同时保证更高的准确率。

**关键词:** 防空反导; 攻击意图识别; 深度神经网络; GeLUs; AdaMod

## Target Attacking Intention Identification of AdaMod Optimization Model Based on Deep Neural Network

WANG Jiabin<sup>1</sup>, WANG Ruiqi<sup>2</sup>, MENG Haibo<sup>2</sup>, LIN Hongming<sup>2</sup>, CHEN Tianqun<sup>2</sup>

(1. Haizhuang is Stationed in a Department in Shanghai, Shanghai 201109, China;

2. Shanghai Institute of Mechanical and Electrical Engineering, Shanghai 201109, China)

**Abstract:** Naval ship air defense and antimissile operations based on target attack intention recognition are research hotspots in naval ship air defense technology. The attack intention identification of attacking targets is an important part of battlefield situation analysis. In the past, quantitative analysis is conducted through prior knowledge and probability, and the impact weights of attack intention identification feature values are determined. Deep neural networks can adaptively learn the feature value of target attacking intentions, and learn the correspondence and mapping between feature data and attacking intention recognition through the feature value training of target attacking intentions in small sample sets without prior knowledge. The Gaussian error linear units (GeLUs) activation function and adaptive and momental bound (AdaMod) optimization algorithm are introduced to accelerate the convergence of the model, and solve the problem that the Adam model may not converge to the optimal solution. Experimental results show that the proposed model can effectively identify the attack intent of attacking targets with insufficient prior knowledge and small training data, while ensuring higher accuracy.

**Keywords:** air defense and antimissile; attack intention identification; deep neural networks; GeLUs; AdaMod

## 0 引言

在目前日益紧张的国际局势中, 制海权一直是大国之间博弈的重点, 海上舰艇编队的进攻与防御体系的建立是掌握制海权的关键, 也是各国一直以来研究的重点。在海上作战时, 防空反导一直是主要防御手段, 防空导弹自 20 世纪 50 年代问世以来, 就引起了世界各国的高度关注。在进入 21 世纪后, 随着技术的不断进步与更新迭代, 海上防空体系与高强度空袭体系间的对抗强度愈发激烈, 如何识别敌方来袭目标的攻击意图是提升海上防空反导拦截效率的必要手段。在当下信息化战争时代, 海上战场环境日益复杂, 在军事需求和信息技术双轮驱动下, 海上舰艇编队作

战针对来袭目标攻击意图识别是目前态势分析领域研究的热点, 是防空反导作战中指挥控制决策<sup>[1]</sup>的重要依据。战场的复杂性、瞬时性的影响使得作战指挥控制系统在短时间内无法处理大量战场信息, 指战员无法做出最优决策, 因此需要智能化作战指挥控制系统辅助指战员决策。智能化辅助决策系统提供的分析结果和预测模型可以提高指战员的决策效率与准确性, 提升指挥控制质量。随着分布式杀伤、马赛克战、频谱战等新型作战样式与新型武器的应用, 强敌海上作战体系具备较强的多域体系作战和网络中心作战能力, 对我国领海安全构成重大威胁。强敌新型作战概念与方式的运用, 增加了海上防空反导指战员对于来

收稿日期: 2023-03-31; 修回日期: 2023-04-10。

作者简介: 王家鑫(1971-), 男, 安徽六安人, 硕士, 高级工程师, 主要从事 DD 武器系统研制与生产方向的研究。

引用格式: 王家鑫, 王瑞琪, 孟海波, 等. 基于深度神经网络 AdaMod 优化模型的来袭目标攻击意图识别[J]. 计算机测量与控制, 2023, 31(6): 274-279.

袭目标攻击意图的识别在短时间内做出准确判断的难度, 对作战指挥控制的战略战术安排产生了至关重要的影响。

目标攻击意图识别是通过量化分析来袭目标的各项参数指标, 以此判断来袭目标可能锁定打击的我方舰艇, 进而辅助防空反导指挥员根据敌方作战意图制定作战决策, 从而提高防空反导拦截效率以及减少我方舰艇作战损耗。根据目标的攻击意图生成合理的防空反导拦截方案是防空作战的重要组成部分。由于分析过程会受到未知与不确定因素的影响, 现有模型的预测准确率得不到很好的验证。现有研究主要基于模板匹配<sup>[2]</sup>、专家经验模型<sup>[3-4]</sup>、层析分析法等<sup>[5-6]</sup>、弹道预测等<sup>[7]</sup>, 严重依赖专家经验生成的权重系数, 不仅过于主观, 也不适用新的作战样式。

2016 年提出使用神经网络自适应学习能力<sup>[8]</sup>, 从训练数据中提取特征规则并用于目标攻击意图识别<sup>[9-10]</sup>。此方法能够解决先验知识及专家经验不足情况下分析与识别目标攻击意图的难点<sup>[11]</sup>, 但是由于采用了简单的 BP (反向传播算法) 算法, 不仅收敛速度慢, 而且容易达到局部最优, 无法收敛到最优解。2018 年有学者使用神经网络对空中目标的作战意图进行识别, 采用了 Adam 优化器和 ReLU (rectified linear unit)<sup>[12-20]</sup> 激活函数, 但是存在 Relu 激活函数在学习率较大的情况下容易导致神经元坏死的问题, 同时 Adam 优化器在这类问题可能出现无法收敛到最优解的问题。

文中提出了一种针对深度神经网络优化后的预测模型<sup>[13-14]</sup>, 分析了来袭目标对我方单个目标的打击概率, 综合考虑各项参数量化分析结果得出来袭目标的攻击意图识别, 有效解决以往评估方法的不足<sup>[17]</sup>。文中采用 GeLUs<sup>[18]</sup> 激活函数 (Gaussian error linear units) 作为激活函数解决梯度爆炸和梯度消失问题, 并提升模型训练速度。同时采用 AdaMod 优化算法 (adaptive and momental bound)<sup>[15]</sup> 加快模型收敛, 并解决了 Adam 模型可能无法收敛到最优解的问题。文中采取的方法可以更好地解决在先验知识不足的情况下识别目标攻击意图的问题。

## 1 攻击意图特征提取

现有的海上防空反导攻击意图提取方法存在特征识别单一, 不能充分利用获取到的目标信息, 信息深度挖掘不够, 导致对攻击意图的深层次分析不足, 攻击意图识别的稳定性与准确度都不够, 导致往往攻击意图识别出来的结果给与决策者一个错误的判断或者根本没法使用。如何挖掘现有目标信息的各个属性参数信息, 是目前攻击意图识别的难点, 文中从多个角度对攻击意图特征进行提取。

针对敌方来袭目标的攻击行为会遵从一定的规则: 搜索目标、发现目标、锁定目标、打击目标。来袭目标不同的作战行动与攻击行为表现为目标态势信息的改变, 直观表现为目标的各项运动参数及状态发生变化, 可以用来识别其攻击意图。敌方来袭目标在搜索目标和发现目标阶段往往无法识别其攻击意图, 直到其锁定目标并实行打击过

程阶段, 其攻击意图才有明显的特征。由于敌方来袭目标的攻击意图的显现是一个动态的过程, 在不同的阶段会有不同的特征表象, 仅依赖某时刻的目标态势信息识别其攻击意图具有片面性和不确定性。

充分识别来袭目标特征属性, 了解目标的特殊属性与攻击意图, 以达到充分挖掘信息的目的, 可以依据不同阶段, 各个特征点属性不同来得到不同的数据集, 可以更好地优化属性得到更理想的结果。

由于敌方来袭目标的意图和状态间存在特定的联系, 文中根据专家经验选取了部分参数: 目标坐标  $(x, y, z)$ 、目标速度  $Vt$ 、速度方向  $\varphi_i$ 、目标加速度  $a_i$ 、加速度方向  $\varphi_i$ 、目标俯冲角  $\theta$ , 目标径向速度  $V_r$ , 目标径向到达时间  $T_r$ , 我方舰艇坐标  $(x_i, y_i, z_i) i \in 1, \dots, k$ ,  $k$  为我方编队舰艇数量)。文中选取舰艇数量为 5 的典型编队配置, 训练样本数据集 (data) 的每一项为  $5 \times 25$  形状。根据训练样本数据集在不同阶段得到的特征不同, 但是攻击意图识别的结果相同, 就可以优化模型参数, 提取其重要特征, 以达到相对较好的结果, 为攻击意图的预测提供有效的数据训练基础。

### 1.1 归一化处理

文中选取的特征数据均为数值数据, 可以使用神经网络直接处理。由于数据在各评价指标下的性质不同, 通常具有不同量纲和数量级, 为保证结果可靠性, 加快数据收敛速度, 以及降低奇异数据对算法的敏感度, 需要对原始数据进行归一化处理。数据的归一化是将数据按比例缩放到一个特定区间, 将数据统一映射到  $[0, 1]$  区间上。设  $MinA$  和  $MaxA$  分别是属性  $A$  的最小值和最大值, 将  $A$  的一个原始值  $x$  映射到区间  $[0, 1]$  的值  $x'$  的公式如下:

$$x' = \frac{x - MinA}{MaxA - MinA} \quad (1)$$

式 (1) 用于模型训练的数据集中的数据全部进行归一化处理。转化后用于模型的学习数据为矩阵  $\mathbf{A}(n)$ , 矩阵  $\mathbf{A}(n)$  的行数为 5, 列数为 25, 归一化处理后的  $\mathbf{A}(n)$  为:

$$\mathbf{A}(n) = \begin{bmatrix} 0.62 & 0.68 & 0.97 & 0.48 & 0.26 & 0.17 & \dots \\ 0.15 & 0.98 & 0.68 & 0.76 & 0.49 & 0.98 & \dots \\ 0.68 & 0.38 & 0.49 & 0.64 & 0.39 & 0.73 & \dots \\ 0.25 & 0.48 & 0.67 & 0.29 & 0.98 & 0.96 & \dots \\ 0.76 & 0.89 & 0.45 & 0.35 & 0.44 & 0.98 & \dots \end{bmatrix}$$

### 1.2 生成攻击意图标签

在未来智能化时代, 战场数据呈现海量形态, 智能化的指挥与辅助决策手段将被广泛运用, 作战空间由物理域、信息域向认知域加速拓展, 对指挥控制的精确性、时效性、实用性提出了更高的要求。由于战场环境复杂, 信息量巨大, 敌方攻击行为和作战样式不断涌现并且复杂多变, 仅依赖领域专家难以在短时间对目标信息进行分析。以下两种数据来源可用于生成目标攻击意图识别标签:

1) 由真实作战或实战演练数据提供的来袭目标攻击意图记录;

2) 由领域专家根据不同的态势判断敌方目标的攻击意图;

如图 1 所示, 典型水面舰艇编队配置如下, 每艘舰艇都拥有相应编号。




图 1 水面舰艇编队配置

样本数据对应的攻击意图转化后用于模型学习的标签数据为矩阵  $S(n)$ , 由专家识别或记录后标记的矩阵为:

$$S(n) = [0 \ 1 \ 0 \ 0 \ 0]$$

其中数据的索引值对应舰艇编号, 数值 1 代表攻击意图识别分析结果识别对应编号的舰艇被敌方锁定攻击, 数值 0 代表未被锁定。来袭目标攻击意图的识别结果同样为格式相同, 数据不同的矩阵, 数值为 0~1 之间的概率值。经过 one-hot 处理后生成的识别结果与标签数据完全一致。

## 2 攻击意图识别模型构建

传统基于来袭目标攻击意图特征识别来辅助指挥者决策的方法, 是需要大量的领域内专家经验对来袭目标攻击意图特征的权重、先验概率等进行先验量化, 明确目标攻击意图特征之间的对应关系, 但是战场形式一旦发生变化, 此种方法会由于缺乏灵活性与自由度, 往往会导致指挥者决策失误, 这是基于先验知识确定来袭目标攻击意图特征的最大不足。

而神经网络可以在领域专家先验知识不足条件下, 通过自身训练得到来袭目标攻击意图特征之间的规则。针对传统的神经网络算法在更新网络节点权值时收敛速度慢、容易陷入局部最优的问题, 通过引入 GeLUs 激活函数和 AdaMod 优化算法, 设计了基于深度神经网络的来袭目标攻击意图识别模型。

### 2.1 深度神经网络

人工神经网络由称为神经元的简单元素构成, 这些元素具有真实值, 乘以权重, 然后通过非线性激活函数运行。深度神经网络 (DNN) 具有多个处理输入的神经元“隐藏层”, 隐藏层中的每个神经元都会接收部分输入变量, 然后将其结果传递给下一层, 网络可以学习非常复杂的功能。深度学习网络更准确, 随着添加更多的神经元层可以进一步提高准确性。只要有足够的计算能力, 神经网络就能够学习任何函数的形状。神经网络的优点是对于高维问题非常有效, 能够处理变量之间的复杂关系, 可以更好的提取数据特征, 在领域专家先验知识不足的情况下根据态势数据进行训练, 用于来袭目标攻击意图识别。强大的调整选项可防止过拟合 (over-fitting) 和拟合不足 (under-fitting), 防止领域专家的主观性对训练结果产生影响。




图 2 深度神经网络结构图

### 2.2 Gelus 激活函数

深层神经网络存在梯度消失和梯度爆炸的问题, 都是因为网络层数太深而引发的梯度反向传播中的连乘效应, 其连乘后结果变得很小导致梯度消失。Sigmoid 激活函数<sup>[19]</sup>在深层神经网络中极大率会引起梯度消失, 还有很小的概率出现梯度爆炸。常用的 Relu 激活函数解决了梯度消失的问题, 但是可能导致神经元死亡, 权重无法更新。近期的 Leaky-ReLU 解决了 Relu 中的神经元死亡问题, 但是其中的超参数  $\alpha$  需要人工调整。后期的 PReLU 和 RReLU 激活函数都是针对超参数  $\alpha$  进行优化调整<sup>[12]</sup>。ELUs 是试图将激活函数的平均值接近零, 从而加快学习的速度。同时通过正值的标识来避免梯度消失的问题。

为改善深层神经网络的性能, 需要一种新的激活函数模型, 使其在学习过程中, 能同时对激活函数的陡度, 位置及映射范围进行调节, 降低深层神经网络存在梯度消失和梯度爆炸的问题发生率, 且具有更强的自我修复能力, 提高模型的拟合能力与收敛速度。

GeLUs 是一个新的激活函数, 它引入了随机正则的思想, 直观上更加符合高斯分布, 实验效果强于 Relus。GeLUs 不仅解决了深层神经网络的梯度消失和爆炸问题, 同时对于模型的拟合能力和收敛速度起着至关重要的重用, 公式如下:

$$xP(X \leq x) = x\Phi(x) \tag{2}$$

其中:  $\Phi(x)$  指的是  $x$  的高斯正态分布的累积分布。

式 (2) 可近似表示为:

$$xP(X \leq x) = x\sigma(1.702x) \tag{3}$$

其中:  $\sigma$  的选择比较关键。

## 3 基于 AdaMod 算法的深度神经网络模型

### 3.1 Adam 优化器

深度学习通常需要大量时间和计算机资源进行训练, 这也是困扰深度学习算法发展的主要原因。优化算法可以使用更少资源并使得模型收敛更快, 从根本上提高了机器学习的速度和有效性。Adam 算法就是以为快速收敛为目的而设计的。自适应矩估计 (Adam) 是一种在神经网络中被广泛采用的优化器, 是一种对随机目标函数执行梯度优化的算法。由于 Adam 算法梯度的对角缩放 (diagonal rescaling) 的不变性, 适用解决大规模参数以及稀疏梯度的非稳态问题。Adam 算法只需要一阶梯度和很小的内存, 通过第

一第二梯度的估计来计算不同参数的自适应学习速率。此外 Adam 算法的超参数可以直观的解释, 不需要大量调参。

### 3.2 AdaMod 优化器

由于 Adam 算法的收敛性较差, 为了保证更优的结果, 文中采用了名为 AdaMod 的优化算法, 这是一种基于 Adam 的改进优化器, 可以在训练的同时计算自适应学习率的指数长期平均值, 根据长期平均值对学习率进行修剪, 去除过高的学习率。相比 Adam 优化器, AdaMod 能够从训练开始就控制自适应学习率的变化, 无需预热。AdaMod 优化器不仅能够使用更少资源加快模型收敛, 同时也不需要进行大量调参就可以使模型得到一个稳定可靠的结果。

### 3.3 算法实现

算法 1: Adam

输入: 初始参数  $\theta_0$ , 步长  $\{\alpha_t\}_{t=1}^T$ , 瞬间衰减  $\{\beta_1, \beta_2\}$ , 正则常数  $\epsilon$ , 随标函数  $f(\theta)$

```

1: 初始化  $m_0=0, v_0=0$ 
2: for  $t=1$  to  $T$  do
3:    $g_t = \nabla f_t(\theta_{t-1})$ 
4:    $m_t = \beta_1 m_{t-1} + (1-\beta_1) g_t$ 
5:    $v_t = \beta_2 v_{t-1} + (1-\beta_2) g_t^2$ 
6:    $\hat{m}_t = m_t / (1-\beta_1)$ 
7:    $\hat{v}_t = v_t / (1-\beta_2)$ 
8:    $\eta_t = \alpha_t / (\sqrt{\hat{v}_t} + \epsilon)$ 
9:    $\theta_t = \theta_{t-1} - \eta_t \hat{m}_t$ 
10: end for

```

算法 2: AdaMod

输入: 初始参数  $\theta_0$ , 步长  $\{\alpha_t\}_{t=1}^T$ , 瞬间衰减  $\{\beta_1, \beta_2\}$ , 正则常数  $\epsilon$ , 随标函数  $f(\theta)$

```

1: 初始化  $m_0=0, v_0=0$ 
2: for  $t=1$  to  $T$  do
3:    $g_t = \nabla f_t(\theta_{t-1})$ 
4:    $m_t = \beta_1 m_{t-1} + (1-\beta_1) g_t$ 
5:    $v_t = \beta_2 v_{t-1} + (1-\beta_2) g_t^2$ 
6:    $\hat{m}_t = m_t / (1-\beta_1)$ 
7:    $\hat{v}_t = v_t / (1-\beta_2)$ 
8:    $\eta_t = \alpha_t / (\sqrt{\hat{v}_t} + \epsilon)$ 
9:    $S_t = \beta_3 s_{t-1} + (1-\beta_3) \eta_t$ 
10:   $\hat{\eta}_t = \min(\eta_t, S_t)$ 
11: end for

```

AdaMod 算法比 Adam 算法多出的第九步操作  $S_t = \beta_3 s_{t-1} + (1-\beta_3) \eta_t$ , 其中  $\beta_3$  定义了记忆长度。定义了当前平滑值和过去“长期记忆”(long-term-memory)的关系, 之后从当前学习率  $\eta_t$  中选择最小值从而剔除高学习率。当  $\beta_3=0$  时, AdaMod 等价于 Adam。

## 4 目标攻击意图识别流程

训练深度神经网络模型并输入目标态势对目标攻击意图进行识别, 步骤如下:

1) 从数据记录系统中提取目标参数, 经转换后提取目标特征数据, 并根据作战实际结果记录以及领域专家对结

果的判断生成标签, 数据结构形如  $[0, 1, 0, 0, 0]$ 。其中被敌方锁定的我方舰船标记为 1。

2) 将数据集随机打乱, 并采用 10 折交叉验证 (Cross-validation) 进行训练。实现方式为将初始样本分割为 10 个子样本, 其中 10% 的子样本作为测试集, 其余 90% 样本用于训练。交叉验证重复 10 次, 每个子样本验证一次。

3) 调整深度神经网络结构, 设置隐藏层数和节点数。

4) 输入训练数据到构建的好的神经网络中, 并调整参数。在计算资源充足的情况下并行调试多个模型, 选取最优的模型迭代优化。

5) 将待识别目标特征数据输入训练完成的模型, 对敌方目标攻击意图做出预测。

## 5 模型分析与参数设置

### 5.1 超参数设置

不同的参数和超参数设置决定了模型的精确度。在普通的模型中, 由于刚开始训练时, 模型的权重 (weight) 是随机初始化的, 此时若选择较大的学习率, 可能带来模型的不稳定。通常会选择预热 (Warmup) 学习率的方式, 在最初训练的几个 epoches 中使用较小的学习率, 在预热的小学习率下, 模型可以慢慢趋于稳定, 等模型相对稳定后再选择预先设置的学习率进行训练, 使得模型的收敛速度更快, 模型效果更佳。文中采用了 AdaMod 优化器, 它的优点是对学习率超参数不敏感, 训练曲线更平滑, 并且不需要预热 (Warmup)。从图 3 可以看到即使学习率相差两个量级, 也能收敛到同一个结果。而其他的优化器例如 Adam, 如果不预热, 效果可能非常差, 不能保证达到可用标准。基于此特点, 设置神经网络的学习率  $\alpha=0.05$ , 超参数  $\beta_1=0.9$ ,  $\beta_2=0.99$ ,  $\beta_3=0.999$ , 平滑项  $\epsilon=10^{-7}$ 。

实验结果表明, 通过对模型进行并行训练得到在迭代次数为 200 次左右时, 设置神经网络的学习率  $\alpha=0.05$  的模型表现最好。




图 3 不同学习率下 AdaMod 优化器的精确度

此外, 神经网络隐藏层结构层数的设计会影响模型识别的准确度。图 4 与图 5 分别使用了不同层级的神经网络结构层数来验证使用 AdaMod 优化器的模型对来袭目标攻击意图识别的准确率。从图中可以看到在训练次数 50 次之后, 使用 AdaMod 优化器的模型验证的准确率基本趋于稳定。隐藏层设置为 3 层的准确度相比于隐藏层设置为 1 层的

准确度更加的稳定于准确。当然，如果隐藏层设置的层数越多，其预测的准确度与稳定性也开始下降。原因是层数越多，节点越多，虽然在训练模型上的效果越好，但随之带来模型过拟合问题，会造成稳定性变差，准确度下降。

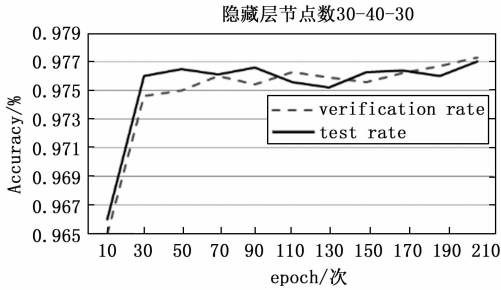


图 4 三层节点神经网络准确率




图 5 五层节点神经网络准确率

### 5.2 模型精度实验

为验证最终模型的精确度，将原数据集再次随机打乱，并抽取前 90% 作为训练样本，剩余的 10% 数据作为测试样本。将训练样本作为模型输入并用测试样本检测模型精确度，测试结果如图 6 所示。在迭代次数为 250 次的情况下，模型的准确率高于 98.4%。从识别结果可以得出结论，该神经网络模型在现有样本的条件下可以有效识别来袭击中目标的攻击意图，同时模型准确率高于 98%，识别可靠性高。

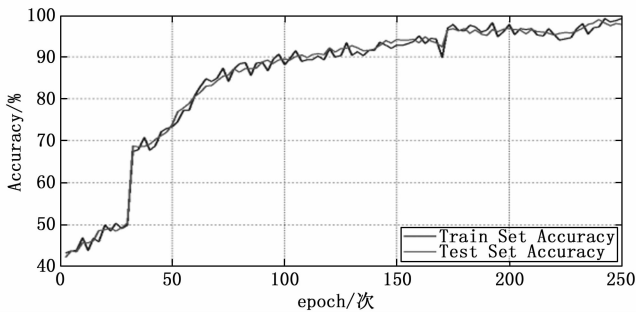


图 6 训练后的模型准确率

### 5.3 实验结果与分析

实验中所提出的激活函数和优化器配置对比基于单层 BP 神经网络模型，普通神经网络模型，Sigmoid 激活函数与 Adam 优化器神经网络模型，ReLU 激活函数与 Adam 优化器神经网络模型的识别效果对比如图 7

所示。

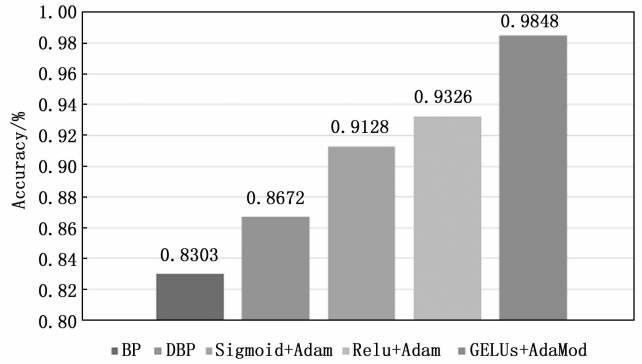


图 7 不同模型准确度对比

由图 7 可知，文中提出的 GELUs 激活函数与 AdaMod 优化器改进的神经网络模型在同样的数据集上能得到比其他模型更好的识别效果。其中使用 Adam 优化器的神经网络模型特定学习率参数设置下收敛存在问题，出现了无法收敛的情况。在不预热的环境下，模型准确率过低，如图 8 所示。作为对比，文中提出的神经网络模型不存在无法收敛到最优解的问题，同时收敛的速度更快，识别效果更好。在保证精度问题的同时，还解决了训练数据量不足的情况下，其他模型训练结果不理想的情况。

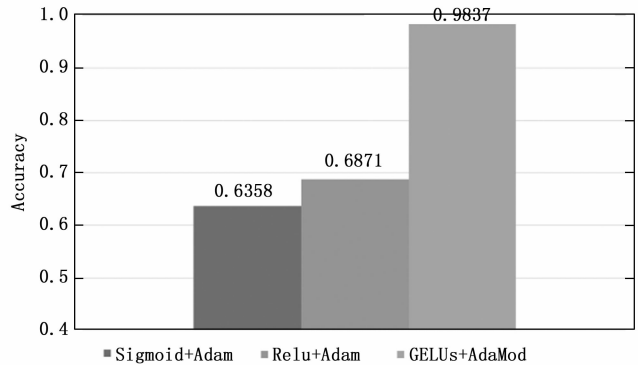


图 8 无预热情况下模型准确度对比

通过上述的模型分析与实验对比可以发现，文中提出的 GELUs 激活函数对神经网络具有更好的泛化能力，可以需要更少的训练样本，得到更好的预测效果，而 AdaMod 优化器让模型有了更好的收敛性与收敛速度，只需要一个较小的样本集对模型进行训练，就可以让敌方空袭目标意图识别结果稳定可靠、准确率高。

故此，采用 AdaMod 优化器与深层神经网络 GeLUs 激活函数的来袭目标攻击意图识别模型有以下几个特点：

- 1) 模型鲁棒性好，结果输出稳定；
- 2) 收敛速度快，样本集需求少；
- 3) 攻击意图特征提取充分，数据挖掘比较完全；
- 4) 模型训练结果可靠性高，准确度高。

当然，由于战场态势千变万化，战场信息错综复杂，受神经网络各参数的初始化数据影响较大，小样本集的训

练可能会有所偏差, 所以此模型有待进一步的改进与提高。

## 6 结束语

文中结合了敌方空袭目标意图识别问题的特点, 提出采用自适应学习率的深度神经网络来解决特征数据庞大, 领域专家知识不足条件下的攻击意图识别问题。

文中选择了当前较为新颖同时效果更好的 GeLUs 激活函数和 AdaMod 优化器对深度神经网络模型进行优化, 最大程度降低了初始学习率设置对模型的影响, 提高了模型收敛速度, 降低训练时间, 同时提高了模型识别效果。此外, 文中设计的模型对训练样本的数量要求更低, 解决了当前样本不足的难点。

深度神经网络模型能够很好地对来袭目标攻击意图进行识别, 有着优异的准确性和可靠性。同时实验结果显示, 该模型的表现由于其他常用模型, 解决了使用 Adam 模型可能出现无法收敛到最优解的问题。

### 参考文献:

- [1] 王航宇, 王士杰, 李 鹏. 舰载火控原理 [M]. 北京: 国防工业出版社, 2006.
- [2] JIANG W, HAN D, FAN X, et al. Research on threat assessment based on dempster-shafer evidence theory [C] //International Conference on Green Communications and Networks, GCN 2011. 2011, 975-984.
- [3] WU Z Q, LI D F. A Model for Aerial target attacking intention judgment based on reasoning and multi-attribute decision making [J]. Electronics Optics & Control, 2010, 17 (5): 10-14.
- [4] 赵捍东, 马 焱, 张 玮, 等. 舰艇对空中来袭目标意图的预判方法 [J]. 中国舰船研究, 2018 (1): 133-139.
- [5] 马立平. 层次分析法——现代统计分析方法的学与用 (七) [J]. 北京统计, 2000 (07): 38-39.
- [6] 吴殿廷, 李东方. 层次分析法的不足及其改进的途径 [J]. 北京师范大学学报: 自然科学版, 2004, 40 (2): 264-268.
- [29] 郭 军, 董新民, 王 龙, 等. 自主空中加油多摄像机近距离相对导航与控制 [J]. 信息与控制, 2012, 41 (1): 95-101.
- [30] ROBINSON J, PIEKENBROCK M, BURCHETT L, et al. Parallelized iterative closest point for autonomous aerial refueling [C] //Advances in Visual Computing; 12th International Symposium on Visual Computing, ISVC 2016. Springer International Publishing, 2016; 593-602.
- [31] ANDERSON J D, NYKL S, WISCHGOLL T. Augmenting flight imagery from aerial refueling [C] // Advances in Visual Computing; 14th International Symposium on Visual Computing, ISVC 2019. Springer International Publishing, 2019; 154-165.
- [32] PARSONS C, PAULSON Z, NYKL S, et al. Analysis of simulated imagery for real-time vision-based automated aerial refueling [J]. Journal of Aerospace Information Systems, 2019, 16 (3): 77-93.
- [7] 魏黎明, 李晓龙, 赵 征, 等. 神经网络在吸气式高超声速导弹突防弹道设计上的应用 [J]. 空天防御, 2018, 1 (2): 14-17.
- [8] 贾苏元, 徐金钰, 王 钰. 基于自适应神经网络模糊系统 (ANFIS) 的空中目标意图图分类 [J]. 电子测量技术, 2016, (12): 62-66.
- [9] 孙一品, 钟求喜, 苏金树. 基于隐马尔可夫模型的攻击意图识别技术研究 [J]. 计算机工程与科学, 2007, 29 (8): 19-22.
- [10] 周旺旺, 姚佩阳, 张杰勇, 等. 基于深度神经网络的空中目标作战意图识别 [J]. 航空学报, 2018, 39 (11): 195-203.
- [11] HARA K, SAITO D, SHOUNO H. Analysis of function of rectified linear unit used in deep learning [C] //International Joint Conference on Neural Networks. IEEE, 2015; 1-8.
- [12] KINGMA D, BA J. Adam: a method for stochastic optimization [J]. Computer Science, 2014; 1-15.
- [13] 郭佰胜, 宫宁生. 激活函数可调的 RBF 神经网络模型 [J]. 微计算机信息, 2009 (6): 240-241
- [14] 全卫国, 李敏霞, 张一可. 深度学习优化算法研究 [J]. 计算机科学, 2018, 45 (Z11): 155-159.
- [15] DING J, REN X, LUO R, et al. An adaptive and momental bound method for stochastic learning [J]. CoRR, 2019; 1-8.
- [16] 蒋昂波, 王维维. ReLU 激活函数优化研究 [J]. 传感器与微系统, 2018 (2): 50-52.
- [17] ZHOU G, SONG C, ZHU X, et al. Deep interest network for click-through rate prediction [P]. Knowledge Discovery & Data Mining, 2018; 1-9.
- [18] HENDRYCKS D, GIMPEL K. Gaussian Error Linear Units (GELUs) [J]. arXiv e-prints, 2016; 1-9.
- [19] 黄 毅, 段修生, 孙世宇, 等. 基于改进 sigmoid 激活函数的深度神经网络训练算法研究 [J]. 计算机测量与控制, 2017, 25 (2): 31-31.
- [20] 许赞杰, 徐菲菲. 基于 ArcReLU 函数的神经网络激活函数优化研究 [J]. 数据采集与处理, 2019, 34 (3): 517-529.
- [33] LEE A, DALLMANN W, NYKL S, et al. Long-range pose estimation for aerial refueling approaches using deep neural networks [J]. Journal of Aerospace Information Systems, 2020, 17 (11): 634-646.
- [34] SUN S, YIN Y, WANG X, et al. Robust landmark detection and position measurement based on monocular vision for autonomous aerial refueling of UAVs [J]. IEEE Transactions on Cybernetics, 2019, 49 (12): 4167-4179.
- [35] 张建花, 高帅华. 基于影像实时处理的加油对接段辅助对准技术 [J]. 应用光学, 2022, 43 (2): 234-239.
- [36] 汪刚志, 王新华, 陈冠宇, 等. 基于视觉的无人机空中加油目标识别技术研究 [J]. 电子测量技术, 2020, 43 (13): 89-94.
- [37] SUN S, YIN Y, WANG X, et al. Robust Visual Detection and Tracking Strategies for Autonomous Aerial Refueling of UAVs [J]. IEEE Transactions on Instrumentation and Measurement, 2019, 68 (12): 4640-4652.

(上接第 273 页)