

7-20-2022

## Aerial Target Threat Assessment Method based on Deep Learning

Huimin Chai

*1.School of Computer Science and Technology, Xidian University, Xi'an 710071, China;2.Science and Technology on Electro-Optical Information Security Control Laboratory, Tianjin 300308, China;;  
chaihm@mail.xidian.edu.cn*

Yong Zhang

*2.Science and Technology on Electro-Optical Information Security Control Laboratory, Tianjin 300308, China;*

Xinyue Li

*1.School of Computer Science and Technology, Xidian University, Xi'an 710071, China;*

Yanan Song

*1.School of Computer Science and Technology, Xidian University, Xi'an 710071, China;*

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research](#), [Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

---

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

---

## Aerial Target Threat Assessment Method based on Deep Learning

### Abstract

**Abstract:** Due to many factors of aerial target threat assessment and the lack of self-learning ability of current assessment methods, a deep neural network model for aerial target threat assessment is established using deep learning theory. *In order to improve the fitting effect of the model training, a symmetric pre-training method is given. The hidden layers of the model are pre-trained layer by layer, and finally the whole model is trained.* Sample data and air to air simulation scene experiments are carried out respectively. The experiments results show that the accuracy of the model using the symmetric pre-training method is higher than the other three initialization methods. The accuracy of the model is more than 90% without noise and more than 70% under 10% normal noise, which shows its better robustness.

### Keywords

aerial target, threat assessment, deep learning, symmetrical pre-training

### Recommended Citation

Huimin Chai, Yong Zhang, Xinyue Li, Yanan Song. Aerial Target Threat Assessment Method based on Deep Learning[J]. Journal of System Simulation, 2022, 34(7): 1459-1467.

# 基于深度学习的空中目标威胁评估方法

柴慧敏<sup>1,2</sup>, 张勇<sup>2</sup>, 李欣粤<sup>1</sup>, 宋雅楠<sup>1</sup>

(1. 西安电子科技大学计算机科学与技术学院, 陕西 西安 710071; 2. 光电信息控制和安全技术重点实验室, 天津 300308)

**摘要:** 针对空中目标威胁评估因素多、现有评估方法缺乏自学习能力的问题, 采用深度学习理论建立了空中目标威胁评估的深层神经网络模型。为了提升模型训练的拟合效果, 提出采用对称式的预训练方法, 逐层地对模型中的隐含层进行预训练, 最后对模型进行整体训练。分别通过样本测试集和空空仿真场景进行验证测试, 结果表明: 采用对称预训练方法, 模型的威胁评估准确率高于其他三种预初始化方法; 模型具有较好的鲁棒性, 在无噪声下准确率大于 90%, 10% 的正态噪声下, 准确率大于 70%。

**关键词:** 空中目标; 威胁评估; 深度学习; 对称式预训练

中图分类号: TP391.9

文献标志码: A

文章编号: 1004-731X(2022)07-1459-09

DOI: 10.16182/j.issn1004731x.joss.21-0080

## Aerial Target Threat Assessment Method based on Deep Learning

Chai Huimin<sup>1,2</sup>, Zhang Yong<sup>2</sup>, Li Xinyue<sup>1</sup>, Song Yanan<sup>1</sup>

(1. School of Computer Science and Technology, Xidian University, Xi'an 710071, China;

2. Science and Technology on Electro-Optical Information Security Control Laboratory, Tianjin 300308, China)

**Abstract:** Due to many factors of aerial target threat assessment and the lack of self-learning ability of current assessment methods, a deep neural network model for aerial target threat assessment is established using deep learning theory. In order to improve the fitting effect of the model training, a symmetric pre-training method is given. The hidden layers of the model are pre-trained layer by layer, and finally the whole model is trained. Sample data and air to air simulation scene experiments are carried out respectively. The experiments results show that the accuracy of the model using the symmetric pre-training method is higher than the other three initialization methods. The accuracy of the model is more than 90% without noise and more than 70% under 10% normal noise, which shows its better robustness.

**Keywords:** aerial target; threat assessment; deep learning; symmetrical pre-training

## 引言

随着现代战场中空中武器装备水平的不断提高, 空中目标的威胁日益复杂, 需要考虑的影响因素也越来越多, 这也对空中目标威胁评估的方法提出了更高的要求。威胁评估 (threat assessment, TA) 属于多传感器信息融合的高层信息

融合, 是对敌方目标的威胁程度进一步量化和判断的过程<sup>[1]</sup>。威胁评估根据敌我武器装备性能、电子设备性能、我方重点保卫目标、敌我作战条令、策略等, 综合敌方的破坏能力、机动能力及行为意图, 做出关于敌方对我方威胁程度的定量估计, 即给出敌方目标威胁等级的度量。

目前, 目标威胁评估的主要解决思路是综合

收稿日期: 2021-01-27

修回日期: 2021-04-01

基金项目: 装备预研重点实验室基金(6142107190106)

第一作者: 柴慧敏(1976-), 女, 博士, 副教授, 研究方向为信息融合与态势感知。E-mail: chaih@mail.xidian.edu.cn

目标的多种因素,如:目标类型、目标攻击能力、雷达探测能力、目标速度、与我方实体的距离等,以量化评估目标对我方的威胁等级。在威胁评估的量化过程中,所采用的方法主要有:层次分析法<sup>[2-3]</sup>、模糊综合评价法<sup>[4-5]</sup>、多属性决策法<sup>[6-7]</sup>和灰色关联法<sup>[8-9]</sup>等。这些方法都能够在威胁评估过程中,从不同的理论角度综合多个评估因素,给出威胁评估的量化结果。但这些方法需要依据经验给出一些参数,如:模糊综合评价法需要给出评价权重。可以看出,这些经典的方法缺乏一定的自学习能力,无法从复杂的态势威胁数据中学习和建立目标威胁评估模型,已经不能满足现代空战智能化发展的需求。

深度学习是具有多层感知的深层神经网络模型,在非线性表达、多层网络学习、参数自主提取方面有较强的优势,为突破战场态势及威胁评估领域的难点问题提供了一定的技术探索途径<sup>[10-12]</sup>。因此,本文将依据空中目标威胁评估的主要因素,采用深度学习理论构建目标威胁评估模型。

深度学习模型在训练过程中存在梯度消失和爆炸问题,这导致浅层的权重很难被训练,或者很多层的权重修改量很大,从而不能达到较好的学习效果。针对这个问题,很多学者提出对深度学习模型的权重参数按照一定的方式进行初始化,如:用比较小的随机数进行初始化、方差归一化的初始化方法、Glorot和Bengio在其论文<sup>[13]</sup>中采用的初始化方法等。而Hinton等结合深度置信网络(deep belief nets, DBN),设计了非监督式贪心逐层训练算法<sup>[14]</sup>,从结构上对传统人工神经网络进行改进,以解决层次结构相关的优化问题。本文在非监督式贪心逐层训练算法的基础上,采用对称式的预训练方式,从输入层到隐含层,再到输出层逐层进行训练,并将训练的权值参数作为深度学习模型的初始化参数,从训练机制上改善学习的训练问题。

## 1 空中目标威胁评估因素

在对空中目标进行威胁评估时,本文将包括如图1所示的评估因素。

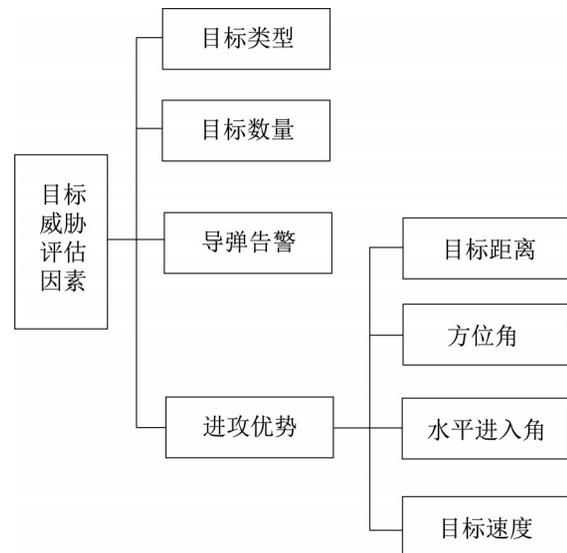


图1 空中目标威胁评估因素  
Fig. 1 Aerial target threat assessment factors

### 1.1 目标类型

敌方目标的威胁评估需要考虑其重要性,对于重要性程度比较高的目标,在对其威胁评估时应该考虑其威胁等级较高。而目标类型作为基本属性,直接决定了目标的重要性。针对不同类型的目标,其战略战术目标价值高的比目标价值低的重要,用于攻击的目标比用于侦察的重要性更高。例如:敌方轰炸机主要的任务是轰炸我方需要保护的目标,则轰炸机就是非常重要的目标,而侦察机则不属于非常重要的目标。

在作战场景中,即使某类型(如:具有攻击能力)的目标没有执行任何任务,但因为其具有攻击性,该类型目标的出现仍对我方具有较大威胁。因此,本文从基本属性的角度,针对不同的目标类型,根据目标的攻击和探测能力将其定为某个重要性等级。具体对空中目标设定6个重要性等级,其中等级数越低,重要性越高。例如:轰炸机为1级,歼击机为2级,侦察机为5级等。

### 1.2 目标数量

本文目标数量是指空中目标群中所包含目标数量, 且空中目标群的所有目标, 其目标类型相同。例如: 轰炸机目标群的目标数量为 5, 是指该目标群共包含有 5 架轰炸机。空中目标群的目标数量越多, 则对我方实体的威胁越大。

针对不同目标类型, 根据目标数量的多少划分威胁等级, 其中等级数越高, 威胁程度越高。如: 轰炸机目标群的目标数量为 1 时, 威胁等级为 1, 当目标数量大于 3 时, 威胁等级为 4。

### 1.3 进攻优势

进攻优势定义为由敌、我目标之间相对几何态势, 而构成的敌方目标对我方实体进攻的潜在优势。进攻优势与目标距离、速度、方位、进入角、攻击距离、探测距离等态势要素有关。

#### (1) 目标距离

目标距离是指敌方目标和我方实体之间的欧式距离, 显然, 目标距离的远近对我方实体构成距离威胁。对于既具有攻击能力, 又具有探测能力的敌方目标, 可以采用式(1)计算其距离威胁  $T_D$ :

$$T_D = \begin{cases} 0, & D > D_{tr} \\ 1 - \frac{D - D_{tw}}{D_{tr} - D_{tw}}, & D_{tw} < D < D_{tr} \\ 1, & D < D_{tw} \end{cases} \quad (1)$$

式中:  $D$  为敌目标距我机的距离;  $D_{tr}$  代表了敌方的雷达能够探测到的最远距离, 即探测距离;  $D_{tw}$  代表了敌方武器能够打击的最远距离, 即为攻击距离。而对于仅具有探测能力的敌方目标, 为了数据计算的合理性, 假设  $D_{tw} = 1 \text{ km}$ 。

#### (2) 方位角和水平进入角

敌方目标相对我方的角度, 会给我方实体造成一定的角度威胁。本文将考虑敌方目标的方位角和水平进入角, 假定敌方目标 A 和我方实体 B, 双方目标的位置和速度。如图 2 所示,  $\varphi$  为目标 A 在我方实体 B 体系下的方位角,  $\theta$  为 A 在 B 体系下

的水平进入角。则敌方目标 A 对我方实体 B 的角度威胁为

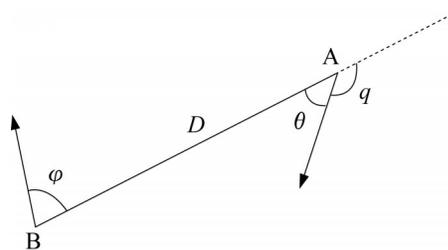


图 2 敌方目标方位角和水平进入角示意  
Fig. 2 Azimuth and horizontal entry angle of enemy target

$$T_a = \frac{|\varphi| - |\theta| + \pi}{2\pi}, T_a \in [0, 1] \quad (2)$$

#### (3) 目标速度

敌方目标速度的大小, 也同样对我方构成速度威胁。对于速度威胁, 采用式(3)计算:

$$T_v = \begin{cases} 1.0, & v > 1.5v_z \\ -\frac{1}{2} + \frac{v}{v_z}, & 0.6v_z < v \leq 1.5v_z \\ 0.1, & v < 0.6v_z \end{cases} \quad (3)$$

式中:  $v$  为敌方目标速度;  $v_z$  为我方实体速度。

可以看出, 敌方目标的距离威胁、角度威胁和速度威胁, 其威胁值越大, 敌方目标对我方实体的作战能力越强。因此, 综合这三项威胁值, 给出该目标对我方的进攻优势:

$$S_1 = w_1 T_D + w_2 T_a + w_3 T_v \quad (4)$$

式中:  $T_D, T_a, T_v$  分别为距离威胁、角度威胁和速度威胁值;  $w_1, w_2, w_3$  分别为距离威胁、角度威胁和速度威胁的权重系数, 其满足  $\sum_{i=1}^3 w_i = 1$  且  $0 < w_1, w_2, w_3 < 1$ 。由于进攻优势  $S_1$  的取值区间为  $[0, 1]$ , 在该区间以均等划分的方式将目标进攻优势分为 8 个等级: 计算结果为  $[0, 0.125)$ , 进攻优势 ( $S_1$ ) 取值为 8; 计算结果为  $[0.125, 0.250)$ , 进攻优势 ( $S_1$ ) 取值为 7; 计算结果为  $[0.250, 0.375)$ , 进攻优势 ( $S_1$ ) 取值为 6; 计算结果为  $[0.375, 0.500)$ , 进攻优势 ( $S_1$ ) 取值为 5; 计算结果为  $[0.500, 0.625)$ , 进攻优势 ( $S_1$ ) 取值为 4; 计算结果为  $[0.625, 0.750)$ , 进攻优势 ( $S_1$ ) 取值为 3; 计算结果为  $[0.750, 0.875)$ , 进攻优势 ( $S_1$ ) 取值为 2; 计算结果为  $[0.875, 1.0]$ , 进攻优势 ( $S_1$ ) 取值为 1。

为2；计算结果为[0.875,1.000]，进攻优势( $S_1$ )取值为1。

本文综合目标类型、目标数量和进攻优势，评估和量化目标的威胁程度，且在量化威胁程度时，考虑了是否发生导弹告警：

$$Z = \begin{cases} p_1 T_1 + p_2 T_2 + p_3 S_1, & \text{当威胁告警为其他} \\ 1, & \text{当威胁告警为导弹告警} \end{cases} \quad (5)$$

式中： $T_1$ 为目标类型； $T_2$ 为目标数量； $S_1$ 为进攻优势； $p_1, p_2, p_3$ 为权值系数，且满足 $\sum_{i=1}^3 p_i = 1$ ， $0 < p_1, p_2, p_3 < 1$ 。由于目标类型、目标数量和进攻优势为等级值：1,2,...,8因此需要将其映射为区间[0,1]上的取值，如进攻优势：

$$S_1 = \begin{cases} 1, & S_1 = 1 \\ 0.875, & S_1 = 2 \\ 0.750, & S_1 = 3 \\ 0.625, & S_1 = 4 \\ 0.500, & S_1 = 5 \\ 0.375, & S_1 = 6 \\ 0.250, & S_1 = 7 \\ 0.1, & S_1 = 8 \end{cases} \quad (6)$$

## 2 基于深度学习的威胁评估模型

### 2.1 深度学习模型

深度学习(deep learning, DL)是在人工神经网络的基础上改进和延伸的产物<sup>[15]</sup>。深度学习最大的特点是含有多层隐含层，目前已成功应用于多个领域，如：机器人控制<sup>[16]</sup>、模式识别<sup>[17]</sup>、信息检索<sup>[18]</sup>等。

本文依据深度学习理论构建威胁评估模型，对空空态势中的空中目标进行威胁评估，其中目标威胁评估因素为：目标类型( $T_1$ )、目标数量( $T_2$ )、导弹告警( $T_3$ )、进攻优势( $S_1$ )。该模型为包含多层隐含层的深层神经网络，如图3所示。

#### (1) 归一化处理

第一层为输入层，输入数据有4个威胁评估因素。

#### (2) 输入层

本文采用sigmoid函数作为激励函数，而输入层数据包括：目标类型、目标数量、进攻优势、导弹告警等多个评估因素，这些评估因素的维度并不相同，因而需要对输入层数据进行归一化处理。为了统一限定整个模型数据的取值范围，同样将输出层数据(标签)进行归一化处理。具体归一化处理方式如式(7)所示：

$$x = \frac{x_{old} - x_{min}}{x_{max} - x_{min}} \quad (7)$$

式中： $x$ 为样本数据进行归一化处理后的值； $x_{old}$ 为原始值； $x_{min}$ 和 $x_{max}$ 为该样本数据的最小值与最大值。

#### (3) 多层隐含层

隐含层的层数和神经元数目的设置并没有理论方法参考，针对具体问题需要通过实验以得到较优的设置方案。本文所使用的样本数据集已经包含输入数据和输出数据(标签)，因此通过实验，不断地人为设置隐含层层数和神经元个数，从中选择构建最优或次优的网络模型结构。

#### (4) 输出层

最后一层为威胁等级层，等级分为8级，每一个节点代表一个威胁等级。

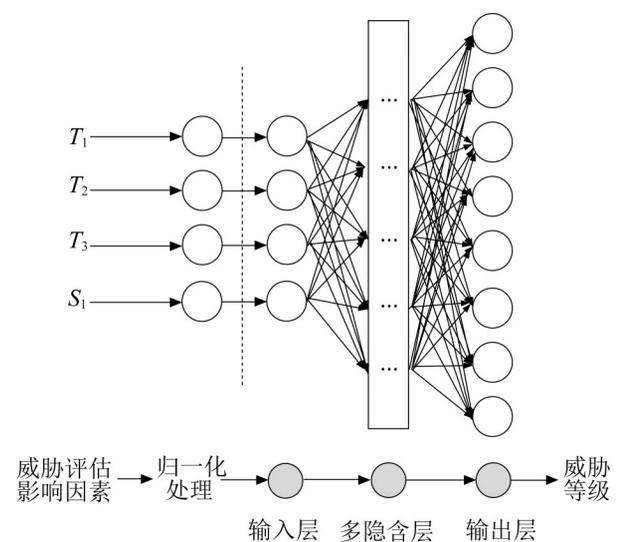


图3 空中目标威胁评估模型

Fig. 3 Aerial target threat assessment model

## 2.2 学习与训练

神经网络的学习与训练主要采用的是反向传播 (back propagation, BP) 算法, 网络参数的初始值随机设定, 采用迭代的方式训练整个网络, 直到收敛。深度学习模型如果也采用这种方式进行模型训练, 会导致时间复杂度太高, 且容易导致梯度扩散。本文仍然采用 BP 算法, 但首先从输入层到输出层逐层进行预训练, 构成对称预训练结构, 其训练的结果作为模型权值参数的初始值; 然后再对模型进行整体训练。具体的训练过程包含如下步骤:

### (1) 第一个隐含层训练

将输入层、第一个隐含层和输出层, 构成一个三层的网络结构, 第一个隐含层作为三层网络的隐含层, 如图 4 中的第一层部分。假定输入层的数据集合记为  $InF = \{in_1, in_2, \dots, in_n\}$ , 其中  $n$  为输入层神经元个数。则针对第一个隐含层的 3 层网络模型的训练集为  $(InF, InF)$ , 即  $InF$  作为输入的同时也作为输出。对该三层的网络进行训练, 即可得到第一个隐含层的初始化权重参数。

### (2) 中间隐含层训练

将第(1)步中隐含层的输出结果同时作为新的三层神经网络的输入和输出, 且将第二个隐含层作为构建新的三层网络的隐含层进行训练, 即可得到第二个隐含层的初始化权重参数。重复第(2)步的训练到最后一个隐含层。如图 4 所示, 当训练到最后一个隐含层时, 即可结束这一步的训练。

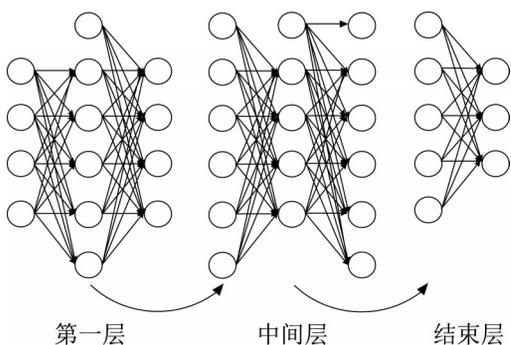


图 4 对称预训练过程

Fig. 4 Symmetrical pre-training process

### (3) 网络模型修正

从第(1)到第(2)步中相应的三层人工神经网络权值参数的训练结果中取值, 作为图 3 中对应隐含层的权值参数的初始值, 但最后一个隐含层与输出层之间的权值则随机取值。接下来继续对图 3 的整体网络模型进行训练, 达到对各层权值修正的效果。可以看出, 本文所采用的这种模型训练方式, 是先获得隐含层的初始权值再进行整体修正, 这样能够有效地提升深度学习模型训练的拟合精度。

## 3 仿真与实验结果

### 3.1 产生模型训练样本数据

基于深度学习的空中目标威胁评估模型需要批量的样本数据进行模型训练, 该部分将依据第 2 节中的威胁评估因素, 以及评估因素与威胁等级之间的计算关系, 采用随机抽样算法 (random sampling algorithm, RSA) 产生样本数据, 包括目标类型, 目标数量, 进攻优势, 导弹告警, 威胁等级, 且目标类型、目标数量、进攻优势、导弹告警和威胁等级关系满足式(5)。样本数据产生的过程如图 5 所示。

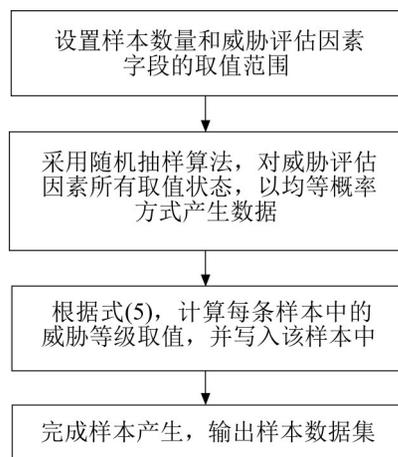


图 5 样本数据产生过程

Fig. 5 Sample data generation process

### 3.2 模型设置与测试内容

本文所建立的空中目标威胁评估深层神经网络模型，设置输入层节点数与空中目标威胁影响因素个数相同，取值为4；输出层节点与空中目标威胁等级个数相同，取值为8；空中目标威胁评估深层神经网络为7层网络，隐含层个数为5。具体设置如表1所示。

表1 空中目标威胁评估深层神经网络模型设置  
Table 1 Specification of deep neural network model for aerial target threat assessment

参数	值
输入层神经元个数	4
隐含层层数	5
各隐含层神经元个数	第一层隐含层 12
	第二层隐含层 11
	第三层隐含层 10
	第四层隐含层 9
	第五层隐含层 25
输出层神经元个数	8
隐含层/输出层激活函数	Sigmoid

需要说明的是，构建深层神经网络模型，隐含层的层数和神经元数目的设置并没有理论方法参考。因此，构建深层神经网络需要通过大量的实践，针对具体问题做具体设置，才能得到较优的方案。本文通过实验对不同隐含层以及各隐含层神经元数目进行了一定的比较，从中选择了较优网络模型的隐含层层数以及各隐含层中节点数目，即表1中的结果。

根据3.1节产生18 000条样本数据，作为模型训练样本集。所有样本的训练次数为600次，每个batch中的样本数据的个数为100条。为了测试模型，从所产生的18 000条样本中随机抽取2 000条样本作为测试数据。具体如表2所示。

为了进行比较，本文在进行模型的训练时，除了本文的对称式预训练的参数权重初始化方法，还采用了以下3种模型权重参数初始化的

表2 空中目标威胁评估深层神经网络模型训练  
Table 2 Deep neural network model training for aerial target threat assessment

参数	值
训练样本总数量	18 000
最大迭代次数	600
每个batch中训练样本个数	100
测试样本数量	2 000

方法：

(1) 方法1：模型的权重参数初始化为：标准正态分布随机数乘以0.01，即 $N(0,1) \times 0.01$ ；

(2) 方法2：采用文献[13]初始化方法，将模型的权重参数初始化为正态分布随机数，期望为0，均方差为 $\sqrt{\frac{2}{sizeInput + sizeOutput}}$ ，其中， $sizeInput$ 和 $sizeOutput$ 分别是输入数量和输出数量；

(3) 方法3：借鉴自编码器的思想，将输入层数据也作为输出层数据，隐含层对称构建；依据表1中的模型设置，构建自编码器结构的网络，该网络从输入层到输出层的神经元个数采用向量表示为[7 12 11 10 9 25 25 9 10 11 12 7]；将该自编码器网络训练后，取前半部分的相应隐含层的权重参数，作为本文模型的初始化权重参数。

本文分别采用测试样本集和场景仿真，对所建立的空中目标威胁评估深度学习模型进行验证测试，测试的指标为目标威胁等级准确率。其中在利用测试样本集进行测试时，与上述3种模型权重参数初始化的方法进行了比较。

### 3.3 样本数据对比测试结果

在模型训练完成后，对模型共进行了20次测试，测试模型的目标威胁等级准确率，每次的测试样本集都是随机选取2 000个测试样本。测试模型的目标威胁等级准确率的计算方式为正确评估

威胁等级的样本个数/2 000。测试结果如表 3 所示, 表 3 中的威胁等级准确率为 20 次测试结果的平均值。

表 3 不同参数初始化方法对比测试结果  
Table 3 Results of different parameter initialization methods %

模型参数初始化方法	威胁等级准确率
本文	96.7
1	35.6
2	36.0
3	35.9

由表 3 可以看出, 本文采用的模型参数初始化方法, 其模型的威胁等级准确率大于 95%。而其他 3 种方法测试的准确率较低, 均没有超过 50%, 方法 2 要略好于方法 1 和方法 3。这也说明深度学习模型的权重参数初始化方式, 对模型的训练效果影响比较大。

为了进一步验证采用本文所建训练模型的鲁棒性, 对测试数据分别加入 5%, 10%, 15% 的正态噪声, 输入模型中测试其准确率, 测试结果如

表 4 所示, 表 4 中的准确率为 20 次实验测试结果的平均值。

实验表明, 加入 10% 的噪声后, 模型仍然具有大于 70% 的准确率。因此, 本文所建立的基于深度神经网络的空面态势威胁评估模型具有一定的鲁棒性。

表 4 加不同噪声后模型准确率  
Table 4 Accuracy of the model with different noises %

测试样本集	威胁等级准确率
未加噪声	96.7
加入 5% 正态噪声	90.1
加入 10% 正态噪声	73.5
加入 15% 正态噪声	61.2

### 3.4 场景仿真测试结果

本节通过仿真软件设置空空仿真场景, 如图 6 所示, 图 6 中蓝色为我方实体, 红色为敌方目标。该场景目标(群)组成为敌方目标总数 52 个, 其中敌方目标群 4 个, 单个敌方目标 40 个; 我方实体 12 个。

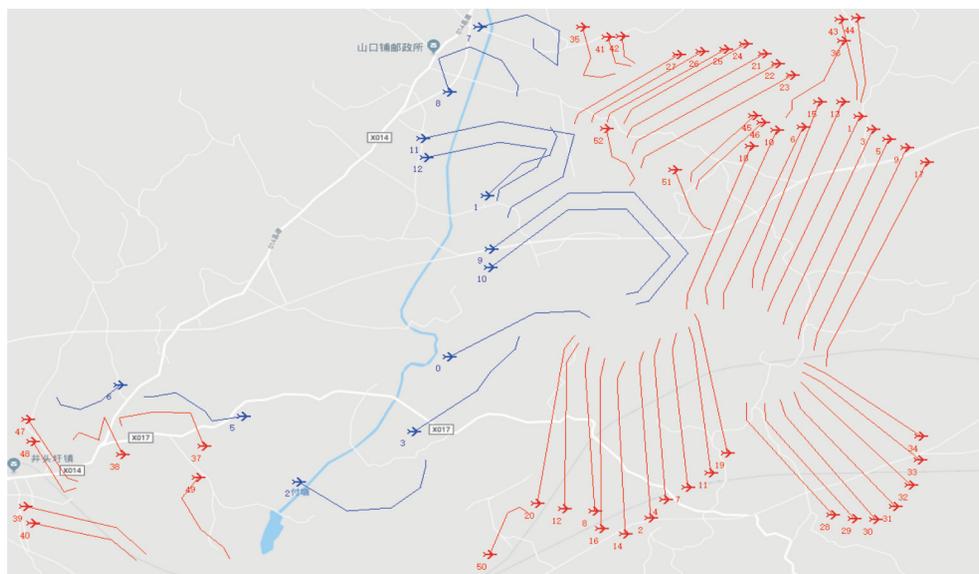


图 6 空空仿真场景

Fig. 6 Air to air simulation scenario

仿真软件依据场景中设置的目标属性、目标航迹产生我方实体、敌方目标的属性和状态数据, 包括: 目标类型、目标速度、目标航向、目标位

置坐标等。从我方实体的角度, 依据第 2 节的计算方式, 分别提取敌方目标(群)的威胁评估因素: 目标(群)类型, 目标数量、进攻优势、导弹告警,

并进行归一化处理,然后输入到空中目标威胁评估深层神经网络模型中。为了衡量威胁模型评估的准确性,同时依据式(5),计算所得威胁评估因素对应的威胁等级。

在仿真过程中,以仿真时间片为间隔,由我方12个目标分别对敌方4个目标群,和除4个目标群之外的40个单个敌方目标,采用进行深层神经网络模型威胁评估。由于仿真测试是每一时间片进行一次威胁评估,因此,该仿真场景测试的威胁等级准确率计算方式为正确评估威胁等级的仿真时间片间隔数/仿真时间片间隔总数。

仿真场景实验结果显示,我方12个目标对敌方4个目标群和40个单个目标的威胁等级评估的正确率均大于90%,且运行相同的场景10次,威胁评估结果和正确率稳定。

## 4 结论

本文利用深度学习理论建立了用于空中目标威胁评估的深层神经网络模型,并通过批量的样本数据进行训练,在训练过程中采用了对称预训练方法,将预训练的参数权重作为模型的初始权重值,使得模型能够达到较高的威胁评估准确率。本文所建模型具有较好的学习能力,能够满足由样本数据建立模型的需求,且样本测试集和空空场景的仿真测试结果表明,该模型能够有效评估空中目标的威胁等级。然而,本文所建模型只是考虑了当前时刻目标的状态,如何综合利用目标的时序状态信息,例如前一时刻或前两个时刻的目标状态信息也参与评估,将是下一步的研究重点。

## 参考文献:

- [1] 赵宗贵,李君灵.信息融合发展沿革与技术动态[J].指挥信息系统与技术,2017,8(1):1-8.  
Zhao Zonggui, Li Junling. Development Evolution and Technological Trend of Information Fusion[J]. Command

- Information System and Technology, 2017, 8(1): 1-8.  
[2] 张恽颀,杨刚,孟海波,等.基于熵-AHP融合的空袭目标威胁度量与排序[J].遥测遥控,2020,41(5):57-64.  
Zhang Yiting, Yang Gang, Meng Haibo, et al. Threat Measurement and Sequencing of Air Raid Targets Based on Entropy Method Fused with AHP[J]. Journal of Telemetry, Tracking and Command, 2020, 41(5): 57-64.  
[3] 孙和强,赵国林,唐飞飞,等.电子对抗无人机作战目标威胁评估[J].舰船电子对抗,2020,43(5):34-37.  
Sun Heqiang, Zhao Guolin, Tang Feifei, et al. Threat Evaluation of Operational Target of ECM UAV[J]. Shipboard Electronic Countermeasure, 2020, 43(5): 34-37.  
[4] 李风华,李勇俊,杨正坤,等.不完全信息下的威胁处置效果模糊评估[J].通信学报,2019,40(4):117-127.  
Li Fenghua, Li Yongjun, Yang Zhengkun, et al. Fuzzy Evaluation for Response Effectiveness in Cases of Incomplete Information[J]. Journal of Communications, 2019, 40(4): 117-127.  
[5] 嵩兴华,陆勤夫,关锦生,等.基于GAHP-模糊综合评价的南海方向潜艇威胁评估[J].指挥控制与仿真,2014,36(5):72-76.  
Hao Xinghua, Lu Qin fu, Guan Jinsheng, et al. Submarine Threat Assessment on the Direction of the South China Sea Based on Group Analytic Hierarchy Process and Fuzzy Comprehensive Evaluation[J]. Command Control & Simulation, 2014, 36(5): 72-76.  
[6] 陈德江,王君,张浩为,等.基于直觉模糊多属性决策的动态威胁评估模型[J].计算机科学,2019,46(4):183-188.  
Chen Dejiang, Wang Jun, Zhang Haowei. Dynamic Threat Assessment Model Based on Intuitionistic Fuzzy Multiple Attribute Decision Making[J]. Computer Science, 2019, 46(4): 183-188.  
[7] 董鹏宇,王红卫,陈游.区间条件下基于GRA和TOPSIS的辐射源威胁评估[J/OL].控制与决策,2020,https://doi.org/10.13195/j.kzyjc.2019.1559.  
Dong Pengyu, Wang Hongwei, Chen You. Combining TOPSIS and GRA for Emitter Threat Evaluation with interval numbers[J/OL]. Control and Decision, 2020, https://doi.org/10.13195/j.kzyjc.2019.1559.  
[8] 徐克虎,张明双,李灵芝,等.基于区间变权灰色关联法的集群目标威胁评估[J].电光与控制,2019,26(12):6-11.  
Xu Kehu, Zhang Mingshuang, Li Lingzhi, et al. Cluster Target Threat Assessment Based on Interval Variable Weight Grey Correlation Method[J]. Electronics Optics & Control, 2019, 26(12): 6-11.  
[9] 孙云柯,方志耕,陈项.基于动态灰色主成分分析的多

- 时刻威胁评估[J/OL]. 系统工程与电子技术, 2020, <https://kns.cnki.net/kcms/detail/11.2422.tn.20200911.1505.036.html>.
- Sun Yunke, Fang Zhigeng, Chen Xiang. Threat Assessment Model Based on Dynamic Grey Principal Component Analysis and Multi-time Fusion[J/OL]. Systems Engineering and Electronics, 2020, <https://kns.cnki.net/kcms/detail/11.2422.tn.20200911.1505.036.html>.
- [10] 郭圣明, 贺筱媛, 吴琳, 等. 基于强制稀疏自编码神经网络的作战态势评估方法研究[J]. 系统仿真学报, 2018, 30(3): 772-784, 800.
- Guo Shengming, He Xiaoyuan, Wu Lin, et al. Situation Assessment Approach for Air Defense Operation System Based on Force-Spased Stacked-Auto Encoding Neural Networks[J]. 2018, 30(3): 772-784, 800.
- [11] 张晓海, 操新文. 基于深度学习的军事智能决策支持系统[J]. 指挥控制与仿真, 2018, 40(2): 1-7.
- Zhang Xiaohai, Cao Xinwen. Military Intelligent Decision Support Systems Based on Deep Learning[J]. Command Control & Simulation, 2018, 40(2): 1-7.
- [12] 朱丰, 胡晓峰, 吴琳, 等. 基于深度学习的战场态势高级理解模拟方法[J]. 火力与指挥控制, 2018, 43(8): 25-30.
- Zhu Feng, Hu Xiaofeng, Wu Lin, et al. Simulation Method of Battlefields Situation Senior Comprehension Based on Deep Learning[J]. Fire Control & Command Control, 2018, 43(8): 25-30.
- [13] Xavier Glorot, Yoshua Bengio. Understanding the Difficulty of Training Deep Feedforward Neural Networks[C]//13th International Conference on Artificial Intelligence and Statistics 2010. Chia Laguna Resort, Sardinia, Italy,: 249-256.
- [14] Hinton G E, Osindero S, Teh Y W. A Fast Learning Algorithm for Deep Belief Nets[J]. Neural Computation (S0899-7667), 2006, 18(7): 1527-1554.
- [15] LeCun Y, Bengio Y, Hinton G. Deep learning[J]. Nature (S1476-4687), 2015, 521(7553): 436-444. Print ISSN.
- [16] 孙辉辉, 胡春鹤, 张军国, 等. 移动机器人运动规划中的深度强化学习[J/OL]. 控制与决策, 2021, <https://kns.cnki.net/kcms/detail/21.1124.TP.20210104.1344.003.html>.
- Sun Huihui, Hu Chunhe, Zhang Junguo, et al. Deep Reinforcement Learning for Motion Planning of Mobile Robots[J/OL]. Control and Decision, 2021, <https://kns.cnki.net/kcms/detail/21.1124.TP.20210104.1344.003.html>.
- [17] 杨路辉, 刘光杰, 翟江涛, 等. 一种改进的卷积神经网络恶意域名检测算法[J]. 西安电子科技大学学报, 2020, 47(1): 37-43.
- Yang Luhui, Liu Guangjie, Zhai Jiangtao, et al. Improved Algorithm for Detection of the Malicious Domain Name Based on the Convolutional Neural Network[J]. Journal of Xidian University, 2020, 47(1): 37-43.
- [18] 胡琦瑶, 杨皓文, 王佳欣, 等. 基于弱监督深度学习的图像检索技术研究[J]. 西北大学学报(自然科学版), 2020, 50(5): 793-801.
- Hu Qiyao, Yang Haowen, Wang Jiixin, et al. Research on Image Retrieval Based on Weakly-supervised Deep Learning[J]. Journal of Northwest University(Natural Science Edition), 2020, 50(5): 793-801.