

doi: 10.7690/bgzdh.2025.09.010

基于深度信念网络的超视距空战效能评估方法

王守权¹, 夏家伟¹, 余红²

(1. 海军航空大学青岛校区, 山东 青岛 266041; 2. 中国人民解放军 92950 部队, 山东 青岛, 266400)

摘要: 为更好地探究效能评估方法的便捷性与高效性, 采用神经网络效能评估的方法对超视距空战中战斗机作战效能进行评估。利用实际训练结果制作样本集标签, 充分挖掘数据本身规律。对 BP 神经网络存在的收敛速度慢、梯度爆炸问题, 采用深度信念网络(deep belief network, DBN)的方法对战斗机作战效能进行评估。结果表明: 该方法能极大程度规避主观性误差, 且评估结果验证了 DBN 模型的有效性和准确性。

关键词: 效能评估; 超视距空战; DBN

中图分类号: TP389.1 **文献标志码:** A

Effectiveness Evaluation Method of Beyond Visual Range Air Combat Based on Deep Belief Network

Wang Shouquan¹, Xia Jiawei¹, Yu Hong²

(1. Qingdao Branch, Naval Aviation University, Qingdao 266041, China; 2. No. 92950 Unit of PLA, Qingdao 266400, China)

Abstract: In order to better explore the convenience and efficiency of effectiveness evaluation method, the effectiveness evaluation method of neural network is used to evaluate the combat effectiveness of fighter in over-the-horizon air combat. The actual training results are used to make sample set labels to fully tap the law of the data itself. Aiming at the problems of slow convergence speed and gradient explosion of BP neural network, the method of deep belief network (DBN) is used to evaluate the combat effectiveness of fighter aircraft. The results show that the method can greatly avoid the subjective error, and the evaluation results verified the effectiveness and accuracy of the DBN model.

Keywords: effectiveness evaluation; beyond visual range air combat; DBN

0 引言

战斗机是重要火力配置单元, 对于遂行空中攻防作战, 夺取局部海域的制空、制海权具有重要意义, 无论是在当下还是未来战争, 都拥有不可或缺的地位和作用。空战时, 最理想的状态是将敌机击落在超视距范围内, 超视距空战是战斗机对远距离的空中目标进行攻击的一种空战模式, 遂行超视距空战任务夺取制空权是战斗机的重要任务。对超视距空战任务下的战斗机进行效能评估, 能够完善作战技术理论, 支撑战斗机改进升级论证。

目前, 国内外对于武器装备的效能评估成果显著。周玉臣等^[1]提出效能评估已经进入高级阶段, 大数据、人工智能等新兴技术在军用领域落地, 利用神经网络进行效能评估成为一大热点。神经网络效能评估是通过建立指标与效能值的强映射关系来达到评估的目的^[2]。神经网络运用于效能评估一经提出就受到众多专家学者的认可和追捧。文献[3-4]对神经网络在效能评估领域的运用历史作了阐述。神经网络运用于效能评估是新兴的评估方法, 比较

经典的是改进的支持向量机、BP 神经网络, 各类深度学习等机器学习方法^[5]。文献[6-7]提出了一种利用 BP 神经网络对武器装备进行效能评估的实践方法; 针对 BP 神经网络处理大样本数据时出现的收敛速度慢、梯度爆炸问题, 文献[8-9]分别提出了利用深度信念网络对机载设备效能进行评估的方法, 在一定程度上提升了收敛速度; 文献[8]则是利用层次分析法构建训练样本, 用神经网络对其进行验证, 但是层次分析法构建样本集存在主观性, 使得预测结果不够准确; 针对层次分析法构建样本出现主观性的问题, 文献[9]利用无标签数据作为训练样本, 归类之后赋予样本标签, 最后利用搭建的深度信念网络直接进行效能评估, 充分挖掘了数据本身的规律。神经网络方法利用机器学习对数据特点的敏感性有效规避了人为因素的影响, 能够稳定地反映各项指标与效能之间的映射关系^[5]。

笔者针对层次分析法权重确定不够客观问题, 采用了基于训练结果的样本制作方法, 解决了权重不客观的问题; 针对 BP 网络收敛速度慢和梯度爆炸问题, 提出了深度信念网络(DBN), 该网络通过

收稿日期: 2024-09-18; 修回日期: 2024-10-10

基金项目: 国家自然科学基金(62271498)

第一作者: 王守权(1975—), 男, 河南人, 硕士。

先分类后微调的方式解决了收敛速度慢和梯度爆炸的问题,最后利用训练好的网络对超视距空战的战斗机进行效能评估,通过对评估结果的分析,验证了 DBN 模型的有效性和准确性。

1 深度信念网络研究

1.1 受限玻尔兹曼机

受限玻尔兹曼机 (restricted Boltzmann machine, RBM) 是一种神经感知器。第 1 层是可视层,即输入层,用来输入样本集;第 2 层是隐含层,用来提取样本集的数据特征。可视层和隐含层的神经元之间为双向全连接,其结构如图 1 所示。




图 1 RBM 网络结构

图 1 为一个可视层,含有 m 个神经元,隐含层含有 n 个神经元的 RBM 结构,每个神经元都有一个偏置,偏置系数 b_i 代表可视层第 i 个神经元的偏置值,偏置系数 c_j 代表隐含层第 j 个神经元的状态值。用向量 \mathbf{v} 和 \mathbf{h} 分别表示可视层输入向量和隐含层输出向量, w_{ij} 表示可视层第 i 个神经元与隐含层第 j 个神经元之间的权重,则此 RBM 的能量函数为:

$$E(\mathbf{v}, \mathbf{h}) = -\sum_{i=1}^m b_i v_i - \sum_{j=1}^n c_j h_j - \sum_{i=1}^m \sum_{j=1}^n v_i w_{ij} h_j. \quad (1)$$

利用能量函数给出状态 (\mathbf{v}, \mathbf{h}) 的联合概率分布函数:

$$P(\mathbf{v}, \mathbf{h}) = e^{-E(\mathbf{v}, \mathbf{h})} / Z. \quad (2)$$

式中 Z 为归一化因子,也称配分函数(partition function)。

$$Z = \sum_{\mathbf{v}, \mathbf{h}} e^{-E(\mathbf{v}, \mathbf{h})}. \quad (3)$$

根据式(2)和(3)得到联合概率分布函数:

$$P(\mathbf{v}) = \sum_{\mathbf{h}} e^{-E(\mathbf{v}, \mathbf{h})}. \quad (4)$$

在可视层神经元状态已知时,第 j 个隐含层神经元激活概率为:

$$P(h_j = 1 | \mathbf{v}) = f\left(c_j + \sum_{i=1}^m w_{ij} v_i\right). \quad (5)$$

f 为 Sigmoid 激活函数:

$$f(x) = 1 / (1 + e^{-x}). \quad (6)$$

由于 RBM 具有对称结构,第 j 个可视神经元的

激活概率为:

$$P(v_i = 1 | \mathbf{h}) = f\left(b_i + \sum_{j=1}^n w_{ij} h_j\right). \quad (7)$$

RBM 训练要达到的最终结果就是通过不断更新参数得到最优模型,根据每个节点的联合概率,对大样本数据进行降维分类,提取数据特征。RBM 运用对比散度算法将可视层神经元初始化为训练样本数据,利用式(1)~(7)计算出隐层神经元状态值,通过式(1)~(5)确定可视层神经元状态值,达到对可视层神经元状态值重构的目的。通过对重构值与初始值的对比得到误差,进而判断是否继续更新参数。

1.2 BP 神经网络

BP 神经网络结构简单,由输入层、隐藏层和输出层组成。它的主要特点是信号正向传播,误差反向传播,其结构如图 2 所示。




图 2 BP 神经网络结构

BP 网络能学习和存贮大量的输入-输出模式映射关系,而无需事前揭示描述这种映射关系的数学方程^[7]。隐含层和输出层都接受来自上层的输入信号,每个信号都通过一个带有权重的连接传递,神经元把这些信号加起来得到一个总输入值,然后对比总输入值与神经元的阈值(模拟阈值电位),并进行反向传播,用来调整网络权重,直到误差在一定范围内反向传播结束,通过“激活函数”处理得到最终的输出(模拟细胞的激活),这个输出又会作为之后神经元的输入一层一层传递下去。

1.3 深度信念网络

深度信念网络模型是由多层 RBM 和一层 BP 神经网络构成,是一种混合网络^[10],结构如图 1—3 所示。在深度信念网络模型中,多层 RBM 网络采用无监督的学习方法,而 BP 神经网络采用有监督的学习方法。自底向上每层 RBM 对输入数据进行提取、抽象,尽可能保留重要信息,将最后一层 RBM 网络的输出信息作为 BP 神经网络的输入数据。由于每层 RBM 的学习训练过程只能使该层网络参数达到最优,而不能使整个网络达到最优,所以要用 BP 神经网络微调整个网络,最终预测结果,既保证了客观性,又不失稳定性。




图 3 深度信念网络结构

在实验中，需要根据自身样本特点对神经元等参数进行设计，将 RBM 的输出结果输入到 BP 神经网络中，与训练样本的标签进行误差计算，对权重和偏置进行微调，进而达到构建 DBN 网络的目的。

2 训练样本生成

2.1 指标体系构建

战斗机在超视距空战过程中，发挥主要功能是战斗机任务系统，包含航电系统和武器系统。各分系统指标种类繁多，指标评估标准各异，指标选取首先要基于 OODA 循环理论，其次是立足于飞机在空战过程中记录下来的任务系统总线数据。指标的选取应遵循最简性、可测性、独立性和客观性原则。

根据 OODA 作战理论，发挥观察和定位功能的主要系统是航电系统的雷达分系统；发挥决策功能的是飞行员，效能从 OODA 环的完成情况体现；发挥行动功能的是武器系统。通过分析得出，超视距空战效能应从雷达探测能力、跟踪能力、OODA 循环能力和导弹攻击能力 4 方面进行指标选取。

雷达探测能力是指拦截引导任务过程中雷达搜索目标的能力，雷达搜索目标距离越大，雷达性能发挥越好，体现雷达探测能力的指标是最大探测距离和探测时间；雷达跟踪能力是指拦截引导任务过程中雷达跟踪目标的能力，体现雷达探测能力的指标是最大跟踪距离和测角精度、测距精度和测速精度；OODA 循环能力是指完成作战回合快慢的能力，对抗空战中飞机完成搜索、跟踪，直到导弹发射的过程称为回合。OODA 循环是一个完整的循环，从循环时间能够体现能量转换，循环过程中，目标一旦丢失意味着 OODA 循环的失败。所以体现 OODA 循环能力的指标是循环时间、不可逃逸距离和目标丢失率。超视距空战时，导弹发射距离，导引头自身功能和导弹是否命中是评估导弹攻击能力的重要

因素。导弹攻击能力应体现在导弹发射距离、导引头截获距离和脱靶量。

根据剖析得到的超视距空战效能的评估指标，建立超视距空战 DBN 指标体系如图 4 所示。




图 4 深度信念网络效能评估指标体系

2.2 训练样本制作

参加超视距空战的战斗机，从搜索目标、跟踪目标到发射一枚导弹的过程称为作战回合，每个回合中均为 1v1 作战，将飞机的胜负结果作为训练样本的标签。其评价规则如下：

战斗机进行对抗空战，结果有 5 种情况。

- 1) 红蓝双方各发射一枚导弹，2 发均命中则红蓝双方飞机均评为良好；
- 2) 红蓝双方各发射一枚导弹，2 发均脱靶，则红蓝双方飞机均评为中等；
- 3) 红蓝双方各发射一枚导弹，只有一方发射的导弹命中，另一方脱靶，则命中方评分为优秀，脱靶方评为中等；
- 4) 红蓝双方只有一方发射导弹，若导弹命中，导弹发射一方评为优，另一方评为差；
- 5) 红蓝双方只有一方发射导弹，若未命中，则导弹发射一方评为良好，另一方评为一般。

根据评价规则，利用空战综合训练系统得出的结果，制作样本集标签，其中评价结果“优秀、良好、中等、一般、差”分别用“5、4、3、2、1”表示。

依据 DBN 指标体系构建样本集：首先，采用超视距空战时多架战斗机的指标构建样本集，以某一回合为例进行训练样本制作分析；然后，对战斗机空战过程中记录的总线数据进行时间对准、坐标转换和计算分析，得到指标体系中最大探测距离、探测时间等 12 项指标的数据并归一化；最后，根据训练评价结果查询得到该回合中待评估飞机发射导弹命中情况和自身是否被击中情况，再根据标签制作评价规则，进行标签的制定。在该回合中，我机与敌机发生空中对抗，我机发射一枚导弹并命中，敌机未发射导弹，则该机评分为优秀，标签为 5。

将上述的 12 项指标数据与其标签对应,即构成一组样本。对训练中多架次战斗机指标数据和对战结果进行计算分析,依据此方法进行样本制作,得到所需样本集共 9 891 条样本,其中部分样本如表 1 所示。

表 1 超视距空战能力评估样本集示例

样本点	最大探测距离	探测时间	最大跟踪能力	测速精度	测距精度	测角精度	OODA 循环时间
1	0.27	0.90	0.26	0.30	0.86	0.38	0.82
2	0.22	0.90	0.20	0.19	0.81	0.92	1.00
3	0.21	1.00	0.20	0.01	0.47	0.01	0.88
4	0.25	0.95	0.24	0.08	0.78	0.56	0.87
5	0.29	0.85	0.34	0.26	0.59	0.78	0.55
6	0.84	0.89	0.29	0.88	0.89	0.77	0.97
7	0.73	0.94	0.97	0.52	0.64	0.80	0.91
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
9 890	0.28	0.95	0.28	0	0.01	0.01	0.65
9 891	0.63	0.80	0.58	0.90	0.01	0.01	0.73

样本点	不可逃逸距离	目标丢失率	导弹发射距离	导引头截获距离	脱靶量	标签
1	0.52	1.00	0.21	0.21	0.68	3.00
2	0.58	1.00	0.19	0.19	0.90	3.00
3	0.51	0.96	0.14	0.14	0.80	3.00
4	0.59	0.99	0.58	0.29	0.15	2.00
5	0.87	0.59	0.67	0.68	0.29	2.00
6	0.29	0.67	0.94	0.05	0.09	1.00
7	0.59	0.60	0.87	0.29	0.15	3.00
⋮	⋮	⋮	⋮	⋮	⋮	⋮
9 890	0.92	1.00	0.01	0.19	1.00	5.00
9 891	0.48	0.96	0.87	0.01	0.16	4.00

3 神经网络设计

网络架构设计主要分为 2 个阶段:1) 搭建初始网络;2) 对初始网络进行调试,直到得到预期网络。

3.1 初始网络搭建

搭建初始网络主要是对初始值的设置,初始值对于网络学习效果的影响非常重要,初始参数包括 RBM 层数、神经元节点数、损失函数、学习速率和误差要求,其中,学习速率是指神经网络学习数据特征的速率,设置过大将导致 RBM 网络的重构误差较快增大,连接权重的变化也会随之变大,可根据样本集特点自行设置。本文中样本集含有 12 个特征,若干样本点,属于大样本数据,故初始学习速率设置较小,值为 0.1;损失函数是指神经网络学习数据特征过程中原始数据的损失值,损失函数值越小,学习效果越好,误差也越小。通过对损失函数收敛程度的判断,可以明确网络调整空间;误差要求是指对预测值和标签均方差值的要求,均方差达到收敛且低于误差要求,标志着网络训练结束,可根据预期结果自行设置;准确率是指达到误差要求值的个数所占样本点总数的比率,可根据预期结果自行设置。

根据指标和数据情况,对初始 DBN 网络进行构建。首先将样本集分为训练集和测试集,分别占比 0.8 和 0.2。DBN 网络分为输入层、隐藏层和输出层。根据表 1 训练样本的数量和包含指标的数量,输入层节点数设置为 12,隐藏层分为 RBM 和 BP

网络,输出层节点为 1。具体 RBM 层数和节点数通过试错法来确定,首先设置一层 RBM 和 BP 网络,RBM 训练次数和 BP 微调次数均为 1 000 次,误差要求低于 0.1,准确率要求达到 80%。

3.2 网络模型调试

初始 DBN 网络搭建好之后,进入网络调试阶段。首先利用训练集进行网络参数的调整;然后利用测试集对网络进行测试,网络收敛后得到的损失函数值及预测准确率如表 2 所示。

表 2 不同节点数 DBN 损失函数值及准确率 %

节点数	损失函数值	预测准确率	节点数	损失函数值	预测准确率
16	1.428	35	64	0.852	45
32	1.036	38	128	1.396	36

表 2 数据显示,含 1 层 RBM 的 DBN 对样本的学习和预测效果普遍较差;但通过结果可以看出,64 节点处损失函数值较其他节点数低,准确率较高。在此基础上通过增加 1 层 RBM 的方式,继续进行实验,结果如表 3 所示。

表 3 双层 RBM 的 DBN 损失函数值及准确率 %

RBM1 节点数	RBM2 节点数	损失函数值	预测准确率
64	16	0.788	56
64	32	0.541	70
64	64	0.315	84
64	128	0.476	78

通过表 2 和 3 得出:2 种结构深度信念网络均是 64 节点时达到效果最优,当节点数达到 128 时,网络效果反而变差,这种现象可能是增加节点数导致网络进入了局部最优解,从而使预测准确率降低。

由此可见，增加神经元的个数不一定会使网络效果更好。

对 2 种结构深度信念网络在 64 节点时误差曲线进行分析。误差曲线如图 5 和 6 所示。




图 5 单层 RBM 的 DBN 64 节点均方差




图 6 双层 RBM 的 DBN 64 节点均方差

通过对比图 5 和 6 可知：2 种网络均方差曲线均达到收敛，双层 RBM 的深度信念网络误差达到了 0.05 以下，远远低于 0.1，得出此网络架构最优。从测试集中随机抽取 100 个样本点对网络预测进行展示如图 7 所示。




图 7 预测值与标签对比

图 7 中，将预测值与标签进行对比，经过统计计算得到：测试集共有 100 个点，其中预测正确点有 86 个，预测错误点有 14 个，网络准确率为 84%。

通过损失函数值计算、均方差曲线、预测值标签对比图和准确率的计算，最终得到超视距空战效能评估的 DBN 模型相关参数设置如表 4 所示。

表 4 超视距空战效能评估网络参数

参数	数值	参数	数值
输入层节点 m	12	隐藏层数量	3
RBM1 节点 n_1	64	学习速率 η	0.1
RBM2 节点 n_2	64	调节次数 t_1	1 000
输出层节点 h	1	微调次数 t_2	1 000
误差要求	0.1		

根据表 4 相关参数，将 DBN 模型导出，得到的网络架构如图 8 所示。




图 8 超视距空战效能评估 DBN 模型

3.3 小结

利用训练好的 DBN 模型，可以对参加超视距空战训练每回合中的双方飞机进行效能评估。比如在某次超视距空战训练第 3 回合中敌机最大探测距离和探测时间归一化值分别为 0.65 和 0.67；最大跟踪距离、测角精度、测距精度和测速精度归一化值分别为 0.67、0.28、0.64 和 0.46；OODA 循环时间、不可逃逸距离和目标丢失率归一化值分别为 0.49、0.61 和 0.35；导弹发射距离、导弹截获距离和脱靶量归一化值分别为 0.42、0.7、0.81；将这 12 项指标数据输入到训练好的网络模型中，得到超视距空战效能评估输出值为 3，评价为中等，与此架机训练中得到的胜负结果一致，故利用 DBN 模型对战斗机超视距空战进行效能评估是合理可行的。

4 结论

运用深度信念网络进行舰载机效能评估是通过作战过程中所产生的数据来进行处理和学习，使网络掌握各种情况下舰载机效能发挥情况，从而全面认识舰载机效能发挥情况，以便利用训练好的网络对后续训练中的舰载机进行效能评估，使得评估过程更加简便，提升了评估效率。

利用网络进行效能评估，样本集必须科学全面。神经网络效能评估的关键在于样本集的建立。本文中，样本集采用的是多批次飞行数据，涵盖优劣等多种飞行情况，学习效果良好。同时，笔者在建立样本集时立足训练胜负结果，不需要确立指标权重，标签与特征关联性强，避免了矛盾，解决了层次分析法存在的权重不够客观的问题。

神经网络虽然具有效率高、客观性强的特点，但是如果样本集不够全面，网络就不能正确认识数据与效能的关系，会出现学习不全面，预测不准确的问题。