

深度置信网络在导弹攻击区分类中的应用*

杨任农,张振兴,房育寰,左家亮,张彬超
(空军工程大学空管领航学院,陕西西安 710038)

摘要:针对传统导弹攻击区解算方法忽略双方态势变化等问题,提出运用深度置信网络的导弹攻击区分类模型。根据导弹命中情况与目标机动间的关系,将导弹攻击区划分为五类。通过分析影响导弹攻击结果的态势参数,构建导弹攻击结果预测模型。在实验部分,结合重构误差和测试错误率确定深度置信网络的网络结构,通过逐层提取数据法分析模型参数特征并且讨论微调数据的采样方式。使用反向传播神经网络和支持向量机进行分类有效性对比实验。实验结果表明:深度置信网络运行速度和预测准确度明显优于其他两种方法,满足实时性和准确性要求,所提方法具有良好的应用价值。

关键词:导弹攻击区分类;深度置信网络;特征提取;微调数据采样

中图分类号:TN95 **文献标志码:**A **文章编号:**1001-2486(2019)02-098-09

Application of deep belief network in classification of missile launch envelopes

YANG Rennong, ZHANG Zhenxing, FANG Yuhuan, ZUO Jialiang, ZHANG Binchao
(Air Traffic Control and Navigation College, Air Force Engineering University, Xi'an 710038, China)

Abstract: Aiming at the problems such as neglecting the dynamic changes in the conventional missile attacking envelop solution, a missile attack envelop classification model based on deep belief network was proposed. The missile attack envelop was divided into five parts according to the relationship between missile hits and target maneuvers. By analyzing the situation parameters which affect the attack result of air-to-air missile, a missile attack prediction model was constructed. In the experiments, the reconstruction error and the test error rate were used to determine the network structure. Through extracting data layer by layer, the features of parameters were analyzed and the approaches of fine-tuning data sampling were discussed. Back propagation network and support vector machine were selected for classification comparison experiments. The results show that the deep belief network performs better than the other two algorithms in speed and prediction accuracy and the presented method is of great practical value.

Keywords: missile attack envelop classification; deep belief network; feature extraction; fine-tuning data sampling

格斗导弹在现代空战中扮演着关键角色,导弹的性能可能决定空战的结果。在空战对抗过程中,空空导弹发射结果是辅助决策系统中态势评估的前提,准确地预测我方和敌方发射导弹的攻击结果,这不仅有助于评估敌方威胁、分析敌我态势,而且对我方下一步决策起到重要的引导作用。因此,探求准确预测导弹攻击结果的方法具有重要意义。

传统的空空导弹攻击区解算方法包括:一般拟合法^[1]、三角变换拟合法^[2]、插值法^[2]等。近年来,很多专家学者针对传统方法存在的拟合精度差、收敛速度低、通用性差等问题进行了改进。张列航等^[3]、王凯等^[4]提出基于反向传

播(Back Propagation, BP)神经网络的空空导弹攻击区解算方法,通过在线计算获得实时的、高精度的空空导弹攻击区计算结果。但模型存在输入数据不准确的问题。左家亮等^[5]采用日常空战中产生的模拟发射数据,构建训练样本库,提高了训练输入数据的准确度。但实际空战输入参数态势种类多,存在简单神经网络特征提取能力不足的问题。此外,上述方法仅侧重于单纯的攻击区解算,忽视了空战对抗情况下双方攻击态势动态变化这一因素对攻击结果的影响。因此,结合机动动作,根据不同态势下预测的攻击结果对导弹攻击区进行划分,从而为飞行员和指挥人员的决策提供帮助。

* 收稿日期:2017-12-31

基金项目:航空科学基金资助项目(20155196022);国家自然科学基金青年科学基金资助项目(71501184);陕西省自然科学基金资助项目(2016JQ6050)

作者简介:杨任农(1969—),男,四川彭州人,教授,博士,博士生导师,E-mail:786918169@qq.com

近年来,以深度学习为代表的人工智能取得了巨大突破,深度学习方法取得了重要进展。而深度学习方法包含多种类型,其中深度置信网络(Deep Belief Network, DBN)具有特征提取能力强、分类效果好以及预测精度高等优点,并且其半监督学习的特点,适合于导弹攻击结果数据库规模小的现状^[6]。因此,提出基于DBN的导弹攻击区分类模型,同时将传统导弹攻击区参数进一步细化,建立更加贴近实战决策的导弹攻击结果预测模型。通过对已经分类的空战数据进行训练,使用得到的模型对导弹攻击区进行分类。但是,由于DBN结构相对复杂,很难准确确定相应的网络结构。黄海波等^[7]使用经验方法确定神经元数目,造成训练误差较大,预测结构不准确。潘广源等^[8]提出了根据训练的重构误差确定网络结构,提高了网络模型的准确性。本文在黄海波等的基础上,使用重构误差和测试错误率作为标准确定网络训练的结构,以提高模型的准确性,并改善网络训练时间。

1 空战攻击结果分析

1.1 导弹攻击区模型

导弹攻击区是衡量导弹攻击结果的重要标准。一般包含两种:发射包线和杀伤包线^[9]。其中,发射包线以被攻击目标为中心,我方飞机在该范围内向目标发射导弹,能以不低于一定概率命中目标。发射包线能够让我方获得不同方位对目标有效打击的范围,对空战决策的意义不是很大。杀伤包线是以我方飞机为中心,计算能被攻击的目标在此载机周围的最远初始位置,在空战中具有重要研究价值。因此,为了能够提供给飞行员和指挥人员重要信息,选择以攻击机为中心的导弹攻击区进行讨论。

以攻击机为中心的空空导弹攻击区主要包括远边界(超过该距离,对敌方无法造成威胁)、近边界(小于该距离,导弹无法爆炸或者载机受到威胁)和侧边界(受导弹的过载限制)。空空导弹发射区如图1所示。

空空导弹攻击区受多种要素的影响,包括天气、飞机高度、飞行速度、导弹性能、目标机速度、目标机高度差等,并且随着发射条件的改变而改变^[10]。根据经验,导弹攻击区的远边界 R_{\max} 和近边界 R_{\min} 是高度 h 、速度 v 、机动过载 n 、离轴角 q 、进入角 q_T 等初始攻击条件的非线性函数^[11]。




图1 空空导弹发射区示意图

Fig. 1 Envelop of air-to-air missile

$$\begin{cases} R_{\max} = R_{\max}(h_A, h_T, v_A, v_T, n_T, q, q_T) \\ R_{\min} = R_{\min}(h_A, h_T, v_A, v_T, n_T, q, q_T) \end{cases} \quad (1)$$

其中: h_A, h_T 表示我方高度和目标高度; v_A, v_T 表示我方速度和目标速度; n_T 表示目标机动过载; q 和 q_T 表示导弹离轴角和目标进入角。

1.2 攻击区划分模型

根据实际空战情况,将导弹攻击区模型主要分成五类:① Ω_1 :目标做任何机动都无法躲开我方导弹攻击;② Ω_2 :目标需要做 180° 置尾机动才能躲开我方导弹攻击,而选择 90° 转弯机动会被导弹命中;③ Ω_3 :目标只需要做 90° 机动即可躲开我方导弹攻击,如果继续按原有航线飞行则会被导弹命中;④ Ω_4 :目标不需要做任何机动即可躲开我方导弹攻击,双方态势处于导弹攻击范围的临界状态;⑤ Ω_5 :双方态势超出导弹攻击范围的上限,攻击有效的概率极低。由于区域 Ω_5 的范围较大,并且对飞行员和指挥人员进行决策的帮助较小,在预测模型中不考虑区域 Ω_5 ,直接通过参数阈值判别。导弹攻击结果划分如图2所示。

在图2中,A为攻击机,T为目标机,目标机处于攻击机的 Ω_3 区域内。在北东天惯性坐标系下,攻击机的坐标为 (x_A, y_A, z_A) ,目标机的坐标为 (x_T, y_T, z_T) ,攻击机高度为 h_A ,目标机高度为 h_T ,攻击机速度为 v_A ,目标机速度为 v_T ,攻击机航向角为 φ_A ,目标机航向角为 φ_T 。位置关系式为:




图 2 导弹攻击结果划分

Fig. 2 Classification of missile attack results

$$\alpha_{A,T} = \begin{cases} 180^\circ - \arctan \left| \frac{y_T - y_A}{x_T - x_A} \right| - \varphi_A, x_T - x_A < 0 \text{ 且 } y_T - y_A \geq 0 \\ 180^\circ + \arctan \left| \frac{y_T - y_A}{x_T - x_A} \right| - \varphi_A, x_T - x_A < 0 \text{ 且 } y_T - y_A < 0 \\ 360^\circ - \arctan \left| \frac{y_T - y_A}{x_T - x_A} \right| - \varphi_A, x_T - x_A > 0 \text{ 且 } y_T - y_A < 0 \\ \arctan \left| \frac{y_T - y_A}{x_T - x_A} \right| - \varphi_A, x_T - x_A > 0 \text{ 且 } y_T - y_A \geq 0 \\ 90^\circ - \varphi_A, x_T - x_A = 0 \text{ 且 } y_T - y_A > 0 \\ 270^\circ - \varphi_A, x_T - x_A = 0 \text{ 且 } y_T - y_A < 0 \end{cases} \quad (2)$$

$$d_{A,T} = \sqrt{(x_A - x_T)^2 + (y_A - y_T)^2 + (z_A - z_T)^2} \quad (3)$$

$$\beta_{A,T} = \arcsin \frac{z_T - z_A}{d_{A,T}} \quad (4)$$

$$h_{A,T} = h_T - h_A \quad (5)$$

其中： $\alpha_{A,T}$ 表示攻击机 A 攻击目标机 T 的水平方向视线角， $d_{A,T}$ 表示 A 与 T 之间的距离， $\beta_{A,T}$ 表示 A 攻击 T 的垂直方向视线角， $h_{A,T}$ 表示 A 与 T 的高度差。

对攻击机而言，攻击区分类预测可理解为其对其攻击结果进行预测，区域 Ω_1 对目标攻击结果最好；对目标机而言，攻击区分类预测可计算出空战机动区域的威胁程度，区域 Ω_1 威胁程度最高。理论上，对区域 Ω_1 、区域 Ω_2 、区域 Ω_3 、区域 Ω_4 和区域 Ω_5 只能进行大概的估算，无法实现十分精准的分类。由于攻击区分类模型涉及参数多，数据库较大，将采用深度学习算法学习双机在不同态势下的空战结果的数据，进而实现相对准确的攻击区划分。

2 基于 DBN 的导弹攻击结果预测模型

2.1 空战攻击结果预测模型

在超视距空战中，影响导弹攻击结果的态势

参数主要包括： $h_A, h_T, d_{A,T}, v_T, \alpha_{A,T}, \beta_{A,T}, \varphi_A$ 和 φ_T 。基于此，建立攻击机与目标机之间的态势参数与导弹攻击结果的关系，DBN 导弹攻击区分类模型如图 3 所示。




图 3 基于 DBN 的导弹攻击结果预测模型

Fig. 3 DBN-based missile attack results prediction model

2.2 深度置信网络模型

DBN 虽然是一种有监督的深度学习方 法，但是由于其内部是由一系列叠加的受限玻尔兹曼机 (Restricted Boltzmann Machines, RBM) 和 BP 神经网络构成，兼具无监督学习方法的 优势，其网络结构如图 4 所示。

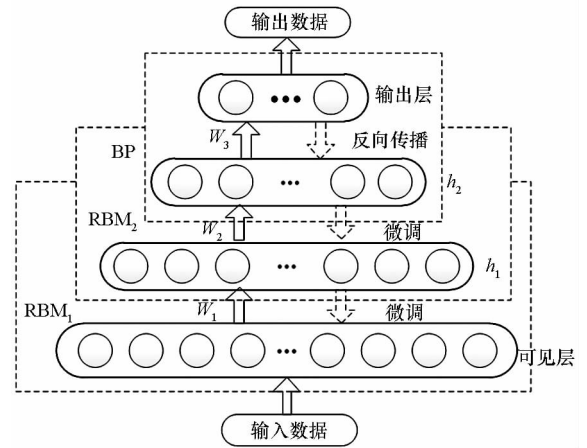


图 4 DBN 结构图

Fig. 4 Structure of DBN

在图 4 中，第一层是可见层，接收输入数据，输入数据经过隐含层 h_1 和 h_2 由输出层输出。 W_i 表示层间权值。

DBN 主要使用“逐层贪婪^[12]”的方法进行训练，处理流程为：①RBM 使用无监督方法进行训练，并且每一层 RBM 需要单独进行训练，尽量保证特征信息被保留，前一层 RBM 的输出作为后一层 RBM 的输入；②无监督训练后输出到 BP 神经网络中，使用有监督方法训练网络，并采用反向传播算法调整网络参数。

在 DBN 中,RBM 起到十分重要的作用,其结构如图 5 所示。




图 5 RBM 网络结构图

Fig. 5 Structure of RBM network

由图 5 可知,RBM 由可见层和隐含层组成, w_{ij} 表示可视层和隐含层之间的权值。

重构误差 $RError$ 为 RBM 的重构特征与原始数据的误差,表达式为:

$$RError = \frac{\sum_{i=1}^n \sum_{j=1}^m (p_{ij} - d_{ij})}{nmp_b} \quad (6)$$

式中: n 表示样本个数, m 表示样本维度, p_{ij} 表示经过 Gibbs 采样重构的新特征, d_{ij} 表示训练数据, p_b 表示取值个数或范围。

2.3 数据采集与训练样本库构建

根据日常空战中产生的模拟发射数据,将不同态势下导弹发射时刻的攻击机与目标机相对态势数据作为模型输入,具体为 2.1 节的八种特征参数。根据文献[13]提出的弹道仿真实论,精确计算在该态势下的攻击结果,并按照结果进行分类,具体有 Ω_1 、 Ω_2 、 Ω_3 、 Ω_4 四种。

结合导弹性能的约束条件对数据采集进行如下定义:

$$\begin{cases} |\alpha_{A-T}| \leq \alpha_{A-Tmax} = 60^\circ \\ |\beta_{A-T}| \leq \beta_{A-Tmax} = 40^\circ \\ |h_{A-T}| \leq h_{A-Tmax} = 5000 \text{ m} \\ 8000 \text{ m} \leq h_A \leq 15000 \text{ m} \\ d_{A-T} \leq d_{A-Tmax} \end{cases} \quad (7)$$


采集的数据必须满足式(7),在此基础上,将态势数据输入到弹道仿真模型中,计算攻击结果。空战攻击结果如图 6 所示,通过为目标机选择不同机动动作,实现导弹攻击结果的进一步划分。

具体步骤如下:


Step 1: 在目标不做任何机动平飞时,仿真弹道没有命中目标则属于 Ω_4 。

Step 2: 如果 Step 1 命中,则在此态势下目标机做 90° 机动,重新进行弹道仿真,仿真弹道没有命中目标且不属于 Ω_4 的区域,则属于 Ω_3 。


Step 3: 如果 Step 2 命中,则在此态势下目标




(a) Ω_4



(b) Ω_3



(c) Ω_2



(d) Ω_1

图 6 空战攻击结果分类

Fig. 6 Classification of missile attack results

机做 180° 机动,重新进行弹道仿真,仿真弹道命中目标的区域属于 Ω_1 ,没有命中且不属于 Ω_3 的区域则属于 Ω_2 。

通过上述步骤,完成 Ω_1 、 Ω_2 、 Ω_3 和 Ω_4 的空战攻击结果数据分类标记。使用弹道仿真方法代替专家人为地进行烦琐且需要大量时间的数据样本分类标记工作,有效地避免了数据标记中的人为主动因素,实现对区域 Ω_1 、 Ω_2 、 Ω_3 和 Ω_4 数据样本的客观分类。

由于攻击机和目标机的高度、速度都是动态变化的,假设按此标准对攻击机的攻击区域进行样本空间拟合,数据量将会相当大。为使训练样本尽可能多地包含空间态势种类,保证训练数据库的完整性,同时考虑实际空战中,攻击机与目标机相互牵制,因此,选择相对态势数据进行拟合。此外,考虑导弹攻击效果与导弹高度的关系,数据采样在高度范围内进行。

3 模型建立与参数训练

从获得的导弹攻击区分类样本库中选取样本,构建 DBN 导弹攻击区分类模型的训练样本集 (X_{train}, Y_{train}) 和测试样本集 (X_{test}, Y_{test}) 。其中, X_{train} 为样本库中随机抽取的 50 000 组数据, X_{test} 为样本库中随机抽取的 10 000 组数据, Y_{train} 和 Y_{test} 分别为每组数据对应的导弹攻击区分类结果。

3.1 DBN 模型隐含层数的确定

由文献[14]可得, DBN 隐含层数和网络重构误差以及模型精度的关系如下:

- 1) DBN 隐含层数目越多,提取输入数据特征的能力越好;
- 2) 网络的重构误差体现了模型对数据的训练程度,重构误差越小,说明训练好的模型越接近训练数据模型;
- 3) DBN 采用的梯度下降法会使训练误差随隐含层数的增加而增大,层数越多,训练难度越大;
- 4) 随着网络层数的增加,训练成本会急剧增大。

由此可知, DBN 隐含层数的选择对于模型的准确性具有重要意义,既要保证模型精度,又要降低训练成本和缩短训练时间。在引入重构误差 $RError$ 的基础上,加入测试错误率 $Error$ 。测试错误率 $Error$ 是指从导弹攻击区分类库中抽取一定量样本进行测试时,模型判别错误的样本数占总测试样本数的比率。隐含层数的确定公式为:

$$\begin{cases} L = N_{rbm} + 1, RError \geq \omega \text{ 或 } Error \geq \zeta \\ L = N_{rbm}, RError < \omega \text{ 且 } Error < \zeta \end{cases} \quad (8)$$

其中: ω 表示设定的目标重构误差, ζ 表示设定的目标精度, L 表示 DBN 隐含层数, N_{rbm} 表示 RBM 隐含层数。整个训练过程是: DBN 首先进行无监督训练,如果 $RError$ 小于或等于设定值,进行下一步的反向微调和数据测试;如果 $RError$ 大于设定值,将隐含层数加 1,重新进行无监督训练,直到 $RError$ 小于或等于设定值。然后进行反向微调与数据测试,并判断 $Error$ 是否小于或等于设定值;如果 $Error$ 大于设定值,将隐含层数加 1,重新进行训练,直到 $Error$ 小于或等于设定值,进而确定隐含层数。DBN 的训练流程如图 7 所示。

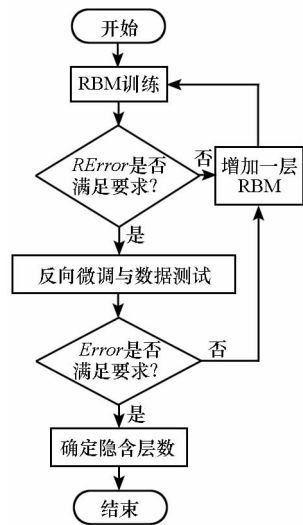


图 7 DBN 隐含层数确定流程图

Fig. 7 Determination flow chart of DBN hidden layers

从训练集中抽取 7000 组数据进行训练和测试,其中,5000 组数据用于无监督训练,并且分成 50 个批次,每个批次 100 组数据;1000 组数据用于有监督训练;1000 组数据用于错误率测试。每个隐含层默认神经元为 100 个,根据样本实际训练情况和文献[9]关于误差阈值的确定方法,将重构误差条件设定为 $RError \leq 15\%$,模型测试错误率 $Error \leq 13\%$ 。考虑到重构误差和分类误差阈值的确定具有一定的主观性,为了检验得到的隐含层数是否最优,在确定最优隐含层数后,增加 1 组隐含层数为最优隐含层数加 1 的实验。通过实验,共得到 4 组不同隐含层数的训练结果,结果如图 8 和表 1 所示。

由图 8 可知, DBN 网络的重构误差随着网络层数的增加而减小,并且隐含层数为 3 和 4 的重构误差相差较小。




图 8 不同层数重构误差图

Fig. 8 Reconstruction error of different layers

表 1 不同层数的训练结果

Tab. 1 Training results of different layers

网络层数	测试错误率/%	训练时间/s
1	24.77	421.757 1
2	13.72	1472.840 7
3	12.82	2260.918 0
4	13.12	3794.757 6

由表 1 可知,测试错误率随着网络层数的增加先减小后增大,并且当网络层数为 3 时达到最小值。训练时间随网络层数的增加而延长,符合预期效果。这说明层数的增加导致反向梯度下降算法的误差累加过大,测试错误率不随着网络层数的增加而一直减小。由此确定 DBN 最优网络隐含层数为 3。

3.2 网络各层节点数的确定

隐含层神经元数目的确定目前还没有统一的方法或者经验公式^[15]。由问题可知,输入层神经元个数 $n_v = 8$,输出层神经元个数 $n_o = 4$,最优隐含层数为 3。考虑到隐含层神经元反映了导弹攻击区模型,并且可以通过降低隐含层神经元数目提取数据特征,将隐含层神经元数目设置为 $n_{h1} = 100, n_{h2} = 80$ 。由于最后一层隐含层神经元数目直接关系到模型最终的准确率,采用类似穷举的方法确定 n_{h3} 的值,其中, $n_{h3} \in [10, 60]$,步长取 2。最后,根据每次得到的重构误差和测试错误率确定最优神经元数目,仿真结果如图 9 和图 10 所示。

由图 9 和图 10 可知,当最后一层节点数目大于 22 时,重构误差几乎保持不变;当最后一层节




图 9 最后一层训练重构误差

Fig. 9 Reconstruction error of the last layer




图 10 最后一层测试错误率

Fig. 10 Test error rate of the last layers

点数目为 30 时,测试错误率最低。因此,选取最后一层神经元数目为 30。

由此可得,最终建立的 DBN 结构为 8 - 100 - 80 - 30 - 4。

3.3 DBN 参数设置

在进行 DBN 训练之前,需要设置模型参数,主要参数如下:

1) 学习率。根据专家经验,设置权重学习率 $l_w = 0.050$,可见层偏置学习率 $l_{bv} = 0.100$,隐含层偏置学习率 $l_{bh} = 0.100$ 。为了避免算法陷入局部最优值,引入动量项。动量更新公式为:

$$W_{ij}^{t+1} = KW_{ij}^t + l_w \frac{\partial \theta}{\partial W_{ij}} \quad (9)$$

式中: K 表示动量项, θ 表示网络参数集, W_{ij} 表示节点间的权重, t 表示迭代次数。

2) 初始权值和阈值。随机初始化权值服从 $N \sim (0, 0.1)$ 的正态分布,输入层和隐含层阈值设置为 0。

3) Batchsize。为了提高运算效率,将训练集分成包含 100 个数据的小批量数据,设置 Batchsize

为 100。

4) 微调次数。微调次数决定模型精度,为了获得较优的微调次数,分别求出不同微调次数对应的测试错误率。不同微调次数的训练结果如图 11 所示。由图 11 可知,当微调次数达到 396 时,错误率基本保持不变,并且满足要求。因此,设置微调次数为 400。




图 11 不同微调次数错误率

Fig. 11 Error rate of different fine-tuning times

4 实验结果与分析

软件平台为 TensorFlow 平台,硬件平台为具有 12 Inter Xeon (R) E5 CPU 和 4 GB RAM 的高性能处理器。

4.1 网络参数特征分析

DBN 模型最终结构为 8 - 100 - 80 - 30 - 4, 通过训练样本集 (X_{train}, Y_{train}) 和测试样本集 (X_{test}, Y_{test}) 对模型进行训练和测试。使用训练好的多层 DBN 对 10 000 组测试数据进行分类,其中用于微调的 400 组数据进行训练集正确率的验证,而其余 9600 组数据则进行测试集正确率的验证。模型训练完成后,逐层提取经过网络后的原始数据特征值,得到特征提取线,如图 12 所示,图中纵坐标为原始数据和各隐含层重构特征,横坐标对应四种区域。

由图 12 可得:四类导弹攻击区具有不同的特征提取线,并且差异较大;根据特征提取曲线可知,导弹攻击区的特征被逐层提取,并且特征数量越来越少。

4.2 微调数据采样方式讨论

在对模型进行微调的过程中,选择样本库数据进行有监督学习称为微调数据采样。微调数据采样方式的不同对于训练效率和模型精度的影响也不同。因此,采用边界采样、等间距采样和随机采样三种方法进行有监督学习。边界采样即提取该区域边缘的数据进行有监督学习,等间距采样即在样本库中等间距选取数据,随机采样即在样本库中随机选取数据。具体采样方式如图 13 所示。

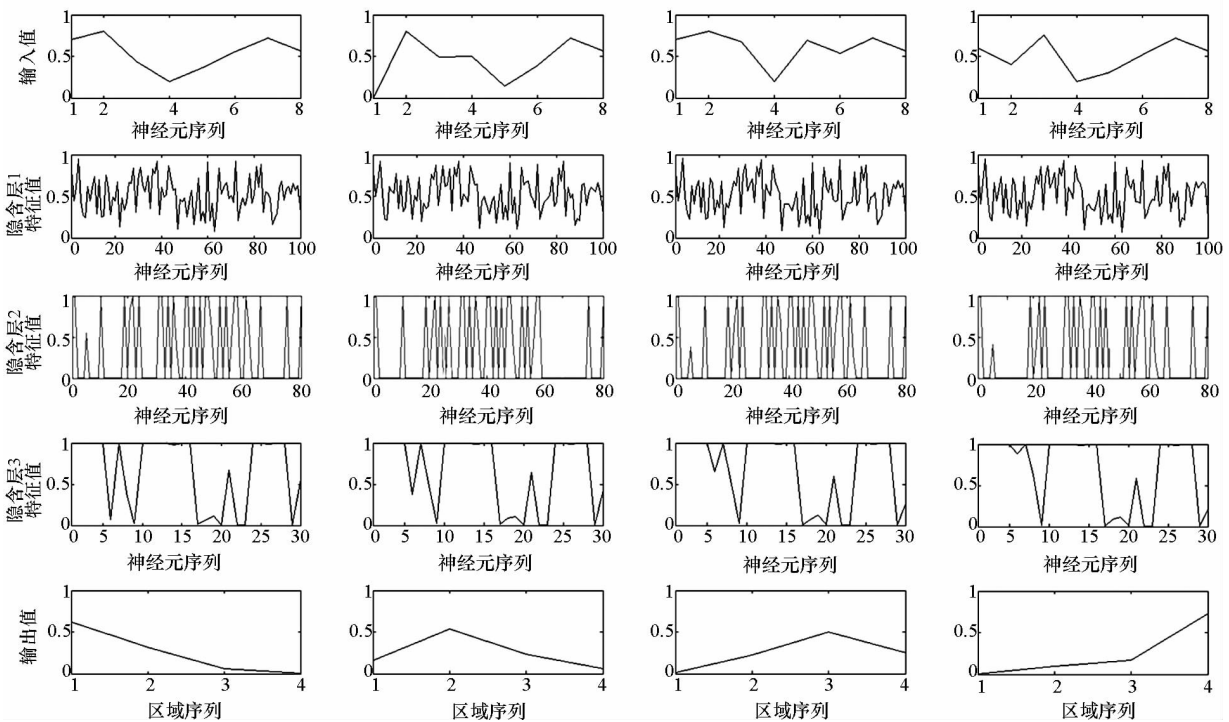


图 12 逐层特征提取线

Fig. 12 Curves of feature extraction layer by layer

采样数量最多,微调训练时间最长,最终达到的正确率上限也最高;随机采样数量适中,最终达到的正确率上限也较高。综上,在实际应用中,随机采样适用性更强,等间距采样和边界采样对样本数据操作更方便。

4.3 分类有效性检验

为检验 DBN 的准确性,分别使用 BP 神经网络(网络结构 8-90-4)和支持向量机(Support Vector Machine, SVM)(径向基核函数,惩罚因子 $c=4$,核函数参数 $g=2.5$)两种方法进行对比分析,三种算法的分类结果如表 3 所示。

表 3 三种算法分类结果对比表

Tab. 3 Comparison of three classification methods

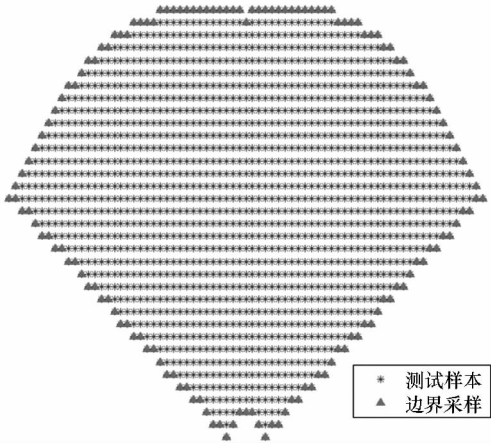
算法	训练集正确率/%	测试集正确率/%	单组数据运行时间/s	内存占用率峰值/%
BP 神经网络	86.88	86.50	0.009 5	1.62
SVM	87.50	86.10	0.004 1	0.82
DBN	92.01	90.07	0.010 4	1.99

由表 3 可知,DBN 的正确率高于 BP 神经网络和 SVM。经过分析,输入数据的维数较高,数据量大,参数变化范围广,而 BP 神经网络规模小,特征提取能力差,SVM 训练成本随着样本量的增加急剧增大,惩罚因子等参数难以确定,两种方法均难以提取态势信息与导弹攻击结果关系的主要特征信息,导致分类正确率不高。而 DBN 通过深层的网络结构,建立了从原始输入到抽象特征的良好映射关系,从而有效地对导弹攻击结果进行分类。

从处理测试集的运行时间和内存占用率峰值两方面性能评价三种算法:BP 神经网络和 DBN 隐含层数目较多,运行时间较长,占用内存多,但是,训练好的 DBN 和 BP 神经网络模型的单组运行时间均满足实时性要求,并且 DBN 的准确性最高,具有实际应用价值。

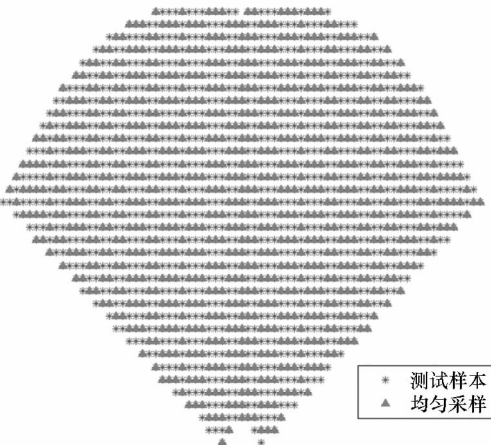
5 结论

本文提出了基于 DBN 的空空导弹攻击区分类模型。构建了导弹攻击结果的样本数据库。根据目标机动方式的不同,结合导弹攻击结果将导弹攻击区分为五个部分。其次根据重构误差和测试误差率确定 DBN 网络拓扑结构,从而完成攻击结果的预测。然后在实验部分搭建 TensorFlow 仿真平台,通过模拟导弹发射过程构建训练样本库,



(a) 边界采样

(a) Edge sampling



(b) 等间距采样

(b) Uniformly sampling

图 13 两种采样形式

Fig. 13 Two sample formations

在保证模型预测精度的基础上,分别使用三种采样方式训练 DBN,将测试集正确率标准定为 85%,测试三种方法达到准确率要求所需要的采样数量,微调训练时间和在该采样方式下最终的正确率,实验结果如表 2 所示。

表 2 三种样本采样方式效果对比

Tab. 2 Comparison of three sampling methods

采样方式	达标采样数量	微调训练时间/s	测试集最终正确率/%
边界采样	110	51.363 8	86.67
等间距采样	600	98.235 8	90.07
随机采样	360	70.022 0	89.98

由表 2 可知,边界采样在采样数量较少时就可以达到较高水平,但最终模型的正确率上限较低,样本的选取也需要对样本库进行操作;等间距

讨论了采样方式的不同对模型结果的影响。最后与 BP 神经网络和 SVM 进行分类对比实验,验证了模型的有效性。使用 TensorFlow 平台实现导弹攻击区分类,主要用于仿真实验部分,在工程实践部分,需要进一步探索实现算法和软件平台。

参考文献 (References)

- [1] 黄国强, 南英, 陈芳. 基于 BP 神经网络的有控炸弹攻击区拟合分析[J]. 弹箭与制导学报, 2009, 29(3): 217-220.
HUANG Guoqiang, NAN Ying, CHEN Fang. Attack zone fitting and MATLAB simulation of guide-bomb based on BP neural network[J]. Journal of Projectiles, Rockets, Missiles and Guidance, 2009, 29(3): 217-220. (in Chinese)
- [2] Shtessela Y S, Shkolnikov I A, Levantc A. Smooth second-order sliding modes: missile guidance application [J]. Automatica, 2007, 43(8): 1470-1476.
- [3] 张列航, 雷蕾, 李研生. BP 神经网络导弹攻击区火控工作式拟合[J]. 火力与指挥控制, 2011, 36(12): 177-179, 183.
ZHANG Liehang, LEI Lei, LI Yansheng. Fire control formula fitting of missile attack envelope based on BP neural network[J]. Fire Control & Command Control, 2011, 36(12): 177-179, 183. (in Chinese)
- [4] 王凯, 李望西, 轩永波. 基于 BP 神经网络的空空导弹攻击区解算及其仿真[J]. 弹箭与制导学报, 2010, 30(1): 75-77.
WANG Kai, LI Wangxi, XUAN Yongbo. The solution and simulation of air-to-air missile launch envelop based on BP neural network[J]. Journal of Projectiles, Rockets, Missiles and Guidance, 2010, 30(1): 75-77. (in Chinese)
- [5] 左家亮, 杨任农, 张滢, 等. 基于启发式强化学习的空战机动智能决策研究[J]. 航空学报, 2017, 38(10): 212-225.
ZUO Jialiang, YANG Rennong, ZHANG Ying, et al. Intelligent decision-making in air combat maneuvering based on heuristic reinforcement learning[J]. Acta Aeronautica et Astronautica Sinica, 2017, 38(10): 212-225. (in Chinese)
- [6] Rezende D J, Mohames S, Wierstra D. Stochastic backpropagation and approximate inference in deep generative models[C]// Proceeding of the 31st International Conference on Machine Learning, 2014.
- [7] 黄海波, 李人宪, 杨琪, 等. 基于 DBNs 的车辆悬架减振器异响鉴别方法[J]. 西南交通大学学报, 2015, 50(5): 776-782.
HUANG Haiibo, LI Renxian, YANG Qi, et al. Identifying abnormal noise of vehicle suspension shock absorber based on deep belief networks [J]. Journal of Southwest Jiaotong University, 2015, 50(5): 776-782. (in Chinese)
- [8] 潘广源, 柴伟, 乔俊飞. DBN 网络的深度确定方法[J]. 控制与决策, 2015, 30(2): 256-260.
PAN Guangyuan, CHAI Wei, QIAO Junfei. Calculation for depth of deep belief network [J]. Control and Decision, 2015, 30(2): 256-260. (in Chinese)
- [9] Scharl J, Mavris D N. Use of flight simulation in early design: formulation and application of the virtual testing and evaluation methodology [J]. Environmental Law Reporter News & Analysis, 2000: 869-872.
- [10] Shtessel Y B, Shkolnikov I A. Smooth second-order sliding modes: missile guidance application[J]. Automatica, 2007, 43(8): 1470-1476.
- [11] 朱建益. 空战中的威胁评估与态势评估研究[D]. 西安: 西安电子科技大学, 2013.
ZHU Jianyi. A study of threat and situation assessment in air combat[D]. Xi'an: Xidian University, 2013. (in Chinese)
- [12] Hinton G E, Salakhutdinov R. Reducing the dimensionality of data with neural network[J]. Science, 2006, 313(5786): 504-507.
- [13] 惠耀洛, 南英, 陈哨东, 等. 空空导弹动态攻击区的高精度快速算法研究[J]. 弹道学报, 2015, 27(2): 39-45.
HUI Yaoluo, NAN Ying, CHEN Shaodong, et al. Research on rapid and high-precision calculation of dynamic attack zone for air-to-air missile[J]. Journal of Ballistics, 2015, 27(2): 39-45. (in Chinese)
- [14] 徐安, 于雷, 寇英信, 等. 基于 MDP 框架的飞行器隐蔽敌策略[J]. 系统工程与电子技术, 2011, 33(5): 1063-1068.
XU An, YU Lei, KOU Yingxin, et al. Stealthy engagement maneuvering strategy for air combat based on MDP [J]. Systems Engineering and Electronics, 2011, 33(5): 1063-1068. (in Chinese)
- [15] 白雪. 基于 DBN 的网络流量分类的研究[D]. 呼和浩特: 内蒙古大学, 2015.
BAI Xue. Research on internet traffic classification using DBN[D]. Hohhot: Inner Mongolia University, 2015. (in Chinese)