

混沌海豚群优化灰色神经网络的空中目标威胁评估

李卫忠¹, 李志鹏^{1,2†}, 江 洋², 刘 唐²

(1. 空军工程大学 防空反导学院, 西安 710051; 2. 空军工程大学 研究生院, 西安 710051)

摘 要: 分析空中目标威胁评估特点, 综合考虑威胁价值、威胁能力和威胁程度, 建立空中目标威胁评估框架; 针对海豚群算法易陷入局部最优和早熟收敛等问题, 提出一种混沌海豚群算法, 将混沌搜索策略引入海豚群算法, 通过混沌初始化、动态分群和早熟优化机制, 提高算法的全局寻优能力; 利用混沌海豚群算法对灰色神经网络的初始参数寻优, 通过搜索到的最优解建立基于混沌海豚群算法优化的灰色神经网络模型, 并用于空中目标威胁评估。仿真实验表明, 混沌海豚群算法优化的灰色神经网络在保证一定收敛速度的基础上, 能够提升寻优精度, 对测试集的预测效果优于传统灰色神经网络和基本海豚群优化的灰色神经网络, 验证了所提算法模型在空中目标威胁评估中的有效性。

关键词: 目标威胁评估; 灰色神经网络; 海豚群算法; 混沌映射; 动态分群; 早熟

中图分类号: TP391.9; E926.4; V274

文献标志码: A

Air-targets threat assessment using grey neural network optimized by chaotic dolphin swarm algorithm

LI Wei-zhong¹, LI Zhi-peng^{1,2†}, JIANG Yang², LIU Tang²

(1. Air and Missile Defense College, Air Force Engineering University, Xi'an 710051, China; 2. Graduate School, Air Force Engineering University, Xi'an 710051, China)

Abstract: Based on analyzing the factors that affect air-targets threat assessment, an air-targets threat assessment model is established based on the target threat value, target threat capability, and target threat level. To solve the problem that the dolphin swarm algorithm is easily trapped into local optimal solution and appears premature convergence, the chaotic dolphin swarm algorithm(CDSA) is proposed on the basis of the basic dolphin swarm algorithm, by making use of chaos to improve the initialization, dynamic clustering and premature optimization. The method employing the chaotic dolphin swarm algorithm to seek the global excellent result to simultaneously optimize the initial weights and thresholds of the grey neural network(GNNM) is presented. And on the basis of it, an air-targets threat assessment model is established. Compared with the GNNM and DSA-GNNM, the simulation results show that the CDSA-GNNM not only improves the global optimization performance, but also obtains robust result with good quality. Through simulation and analysis of experimental data, the effectiveness of the proposed algorithm in the application of air-targets threat assessment is verified.

Keywords: target threat assessment; grey neural network; dolphin swarm algorithm; chaotic map; dynamic clustering; premature convergence

0 引 言

随着远程精确打击等技术的发展, 空中来袭目标突防能力加强, 防空领域所面临的威胁愈加严峻。综合考虑作战态势各影响要素, 合理选取关键性指标建立威胁评估模型, 并对目标威胁作出及时、合理、有效的评估和排序, 是防空作战指挥控制决策的关键环节, 也是衡量制胜能力的重要技术之一^[1]。目前, 目标

威胁评估的方法主要有: 云模型^[2]、贝叶斯网络^[3]、多属性决策法^[4]、支持向量机(SVM)^[5]、神经网络^[6-7]以及模糊理论^[8-9]等。贝叶斯网络等方法多依赖于专家经验, 带有主观性, 对威胁指标间的耦合性考虑不足; SVM算法借助二次规划, 适用于小样本、高维模式识别, 在大规模样本中难以实施; 神经网络具有较强的非线性拟合能力, 但其精度依赖于大规模样

收稿日期: 2017-06-24; 修回日期: 2017-12-04.

基金项目: 国家自然科学基金项目(61503407).

责任编委: 刘德荣.

作者简介: 李卫忠(1968—), 男, 副教授, 从事数据融合、系统建模等研究; 李志鹏(1993—), 男, 硕士生, 从事数据工程与决策支持的研究.

†通讯作者. E-mail: lizhipeng0888@yeah.net

本. 灰色神经网络(Grey neural network, GNNM)将灰色理论与神经网络相结合, 所需样本量小, 学习能力强, 在智能预测领域应用广泛, 但由于参数设置随机性大等问题, 灰色神经网络存在收敛速度慢、易陷入局部最优、预测精度不高和稳定性差等缺点^[10]. 海豚群算法(Dolphin swarm algorithm, DSA)是一种群体智能算法, 具有良好的收敛性和适用性, 在测试函数实验中表现较好, 本文将用于灰色神经网络参数的优化. 针对DSA算法易陷入局部最优的问题, 本文提出一种混沌海豚群算法(Chaotic dolphin swarm algorithm, CDSA), 通过混沌策略进行改进, 并用其对灰色神经网络的初始参数作出修正, 同时针对防空作战目标威胁评估特点, 提出一种目标威胁评估框架, 建立混沌海豚群优化灰色神经网络的目标威胁评估模型.

1 混沌海豚群算法

1.1 海豚群算法

海豚群算法模拟海豚捕食过程, 将最优化问题转化为解空间内的全局搜索问题, 主要包括搜寻、呼叫、接受和捕猎4个阶段^[11]. 设 D 维解空间内, 海豚种群数量为 N , 海豚个体 i 表示为 $X_i = [x_1, x_2, \dots, x_D]^T$, $x_j (j = 1, 2, \dots, D)$ 为个体 i 在第 j 维的取值.

1.1.1 搜寻

海豚通过声波搜寻. 设 $\{V_j\} (j = 1, 2, \dots, M)$ 为个体 i 随机在 M 个方向发出的声波, $\|V_i\| = \text{speed}$, speed 为速度常量. 若最大搜寻时间为 T , 则搜索半径 $R = T \cdot \text{speed}$. 声波 V_j 在时间 t 搜寻到的新解记为 X_{ijt} , 则 $X_{ijt} = X_i + V_j \cdot t$. 若搜寻到的最优适应度值 $\text{fitness}(X_{iab}) = \min_{j=1,2,\dots,M} \text{fitness}(X_{ijt})$, 则认为 X_{iab} 是个体 i 的自寻最优解, 记作 L_i .

1.1.2 联络

本文将呼叫和接受环节合称为联络阶段. 海豚通过呼叫将自寻最优解信息向外传播, 其他海豚则将所接收到的最优解信息与自寻最优解比较, 选择较优者确定为邻域最优解, 记作 K_i . 定义一个 $N \times N$ 联络时间矩阵(transmission time matrix, TM), TM_{ij} 表示声波从海豚 j 到海豚 i 的剩余传播时间, 其值随时间片的运行逐渐减小. 当 $\text{fitness}(K_i) > \text{fitness}(K_j)$ 且 $\text{TM}_{ij} > \left\lceil \frac{d_{ij}}{A \cdot \text{speed}} \right\rceil$ 时, 令 $\text{TM}_{ij} = \left\lceil \frac{d_{ij}}{A \cdot \text{speed}} \right\rceil$, $d_{ij} = \|X_i - X_j\|$, A 为加速度常数, 用于调节声波速度. 当 $\text{TM}_{ij} = 0$ 时, 来自海豚 j 的声波被海豚 i 接收, 此时将 TM_{ij} 重新标记为最大联络时间 T' . 若 $\text{fitness}(K_i) > \text{fitness}(K_j)$, 则令 $K_i = K_j$, 完成

联络.

1.1.3 捕猎

联络过程完成后, 个体依据 K_i 进行位置更新, 位移范围由更新半径 R' 确定, 即 $\|\text{new}X_i - X_i\| = R'$. 设 $d_{K(i)} = \|X_i - K_i\|$, $d_{KL(i)} = \|L_i - K_i\|$, 根据 R 值的大小以及 X_i 、 L_i 、 K_i 三者间的位置关系, 具体过程分3种情况讨论.

1) $d_{K(i)} \leq R$, 即海豚 i 的邻域最优解 K_i 在搜寻范围内, $K_i = L_i$, 如图1所示.




图1 情况1)下的位置更新

此时, X_i 更新为

$$\begin{cases} R' = \left(1 - \frac{2}{c}\right) d_{K(i)}, \\ \text{new}X_i = K_i + \frac{X_i - K_i}{d_{K(i)}} R', \end{cases}$$

其中 $c > 2$ 为衰减系数, 通常取3或4.

2) $d_{K(i)} > R$ 且 $d_{K(i)} \geq d_{KL(i)}$, 即邻域最优解 K_i 在搜寻范围之外, 且 L_i 比 X_i 更接近 K_i , 如图2所示.




图2 情况2)下的位置更新

此时, X_i 更新如下:

$$\begin{cases} R' = \left[1 - \frac{\frac{d_{K(i)}}{\text{fitness}(K_i)} + \frac{d_{K(i)} - d_{KL(i)}}{\text{fitness}(L_i)}}{c \cdot \frac{d_{K(i)}}{\text{fitness}(K_i)}}\right] d_{K(i)}, \\ \text{new}X_i = K_i + \frac{\text{random}}{\|\text{random}\|} R'. \end{cases}$$

3) $d_{K(i)} > R$ 且 $d_{K(i)} < d_{KL(i)}$, 邻域最优解 K_i 在搜寻范围之外, 且 X_i 比 L_i 更接近 K_i , 如图3所示.




图3 情况3)下的位置更新

此时, X_i 更新如下:

$$\begin{cases} R' = \left[1 - \frac{d_{K(i)}}{\text{fitness}(K_i)} - \frac{d_{KL(i)} - d_{K(i)}}{\text{fitness}(L_i)} \right] d_{K(i)}, \\ \text{new } X_i = K_i + \frac{\text{random}}{\|\text{random}\|} R'. \end{cases}$$

海豚位置更新后,重新计算其适应度函数值并作出比较,若 $\text{fitness}(\text{new } X_i) < \text{fitness}(K_i)$,则令 $K_i = \text{new } X_i$. 之后,海豚群进入新一轮搜寻,直至满足终止条件.

1.2 算法改进

DSA算法在迭代中容易出现个体聚于局部极值而造成搜索惰性和早熟现象. 本文引入混沌搜寻策略,通过Logistic混沌映射^[12]修正海豚位置,使DSA算法具有自适应混沌化的能力,利用混沌的无规则运动,增强算法的遍历性.

1.2.1 混沌初始化

在算法优化过程中,种群初始位置的分布与聚集程度将决定种群在整个搜索空间的范围分布是否均匀,从而影响算法的寻优效率.

首先在 $[0, 1]$ 区间上生成 D 个随机数作为混沌序列的初始值 $X_i(0)$,然后根据Logistic方程迭代产生若干混沌序列. 迭代方程为

$$\begin{aligned} X_i(n+1) &= \mu X_i(n)[1 - X_i(n)], \\ X_i(0) &\neq \{0, 0.25, 0.5, 0.75, 1\}. \end{aligned}$$

其中: n 为迭代次数; $X_i(n)$ 为第 n 次迭代时的位置; μ 为混沌控制参数, $\mu = 4$ 时,系统处于完全混沌状态,将充分发挥出混沌“规律性”. 混沌序列会遍历搜索空间.

混沌序列生成后,计算适应度值,选出较优的 N 个序列形成规模为 N 的初始种群.

1.2.2 动态分群策略

利用混沌映射改变个体位置,确保了初始化的随机性和种群多样性,有利于实现搜索域对解空间的全

覆盖,但这势必造成对可行域的重复或过度搜索. 本文提出一种动态分群策略,在迭代中将当前种群分为精英海豚、惰性海豚和普通海豚3个群体,对不同的群体采取不同的策略.

动态分群准则通过适应度值确定: 1) 求出当前海豚群的个体平均适应度 $\bar{f}$; 2) 以 $\bar{f}$ 为界,将适应度优于 $\bar{f}$ 的个体划为优势群,将适应度劣于 $\bar{f}$ 的个体划为劣势群; 3) 分别求出优势群个体平均适应度 $\bar{f}_a$ 和劣势群的个体平均适应度 $\bar{f}_b$; 4) 定义适应度优于 $\bar{f}_a$ 的个体为精英海豚,适应度劣于 $\bar{f}_b$ 的个体为惰性海豚,适应度值介于 $\bar{f}_a$ 与 $\bar{f}_b$ 之间的个体为普通海豚.

精英海豚为当前种群中适应度较好的个体,距当前最优解较近,使其保持不变,继续根据自身所获取的信息进行搜寻、联络和捕猎等操作.

惰性海豚的适应度较差,对种群进化产生阻滞效应. 本文考虑通过混沌搜索产生新序列,并选择较优序列更新惰性海豚,为种群进化重新赋予活力. 惰性海豚混沌激活的具体操作为: 1) 依照混沌初始化的方法,生成混沌序列; 2) 计算序列适应度值,并在迭代中记录序列适应度最优值; 3) 满足设定的混沌搜寻次数后,将得到的最优混沌序列与当前种群的最优解比较,若混沌搜索到的序列位置更优,则用其替换惰性海豚的最优解,否则用此序列替换任一个体.

普通海豚即适应度值介于精英海豚与惰性海豚之间的个体,其在迭代中不会表现出明显的更新方向,随机性更大,对此类个体采取双向驱动,即在基本更新操作的同时进行混沌搜索,为其争取更大的搜索空间.

1.2.3 早熟优化机制

在算法运行早期,若种群出现适应值远超其他个体的海豚,则会导致种群多样性骤减,出现早熟现象. 为此,本文引入早熟优化机制进行改进.

根据种群分布聚集度和适应度离散度判断种群是否早熟. 聚集度通过平均距离 $\bar{D}$ 表示,有

$$\begin{aligned} \bar{D} &= \frac{1}{N} \sum_{i=1}^N \|X_i - \bar{X}\| = \\ &= \frac{1}{N} \sum_{i=1}^N \left\| X_i - \frac{1}{N} \sum_{i=1}^N X_i \right\|. \end{aligned}$$

适应度离散度通过种群适应度方差 δ^2 表示,有

$$\delta^2 = \sum_{i=1}^N (f_i - \bar{f})^2 = \sum_{i=1}^N \left(f_i - \frac{1}{N} \sum_{i=1}^N f_i \right)^2,$$

其中 f_i 表示海豚 i 的适应度值.

为便于处理,对 δ^2 加入归一化因子 f ,有

$$\begin{cases} \delta^2 = \sum_{i=1}^N \left(\frac{f_i - \bar{f}}{f} \right)^2, \\ f = \max\{1, \max_{1 \leq i \leq N} |f_i - \bar{f}|\}. \end{cases}$$

从上述定义不难看出: $\bar{D}$ 越小, 海豚群分布越集中; δ^2 越小, 种群收敛度越高. 为了给种群早熟的判定提供定量依据, 需设置两个判定参数 α 和 β , 当 $\bar{D} < \alpha$ 且 $\delta^2 < \beta$ 时判定种群出现早熟, 此时对当前种群最优解实施混沌映射.

2 CDSA 优化灰色神经网络

灰色神经网络整合神经网络自学习、非线性映射的特点和灰色模型处理小样本的优势, 有效克服了单个模型的机理缺陷, 将灰微分方程的解映射到神经网络, 然后通过神经网络的训练得到微分方程的系数^[13].

灰色神经网络微分方程表达式为

$$\frac{dy_1}{dt} + ay_1 = b_1y_2 + b_2y_3 + \cdots + b_{n-1}y_n.$$

其中: $y_i(t)$ ($i = 2, 3, \dots, n$) 为输入参数, y_1 为输出值. 将上式化为时间响应函数模型, 得

$$z(t) =$$

$$\left[y_1(0) - \frac{b_1}{a}y_2(t) - \frac{b_2}{a}y_3(t) - \cdots - \frac{b_{n-1}}{a}y_n(t) \right] e^{-at} + \frac{b_1}{a}y_2(t) + \frac{b_2}{a}y_3(t) + \cdots + \frac{b_{n-1}}{a}y_n(t).$$

令

$$d = \frac{b_1}{a}y_2(t) + \frac{b_2}{a}y_3(t) + \cdots + \frac{b_{n-1}}{a}y_n(t),$$

则

$$z(t) =$$

$$\left[(y_1(0) - d) \cdot \frac{e^{-at}}{1 + e^{-at}} + d \cdot \frac{1}{1 + e^{-at}} \right] (1 + e^{-at}) = \left[(y_1(0) - d) - \frac{y_1(0)}{1 + e^{-at}} + \frac{2d}{1 + e^{-at}} \right] (1 + e^{-at}).$$

将时间响应函数映射到一个含有 n 个输入参数、1 个输出参数的神经网络中, 如图 4 所示. 其中: LA、LB、LC、LD 表示网络分层, ω_{ij} ($i = 2, 3; j = 1, 2, \dots, n$) 表示网络权值.




图4 网络结构

CDSA 优化灰色神经网络主要包括 3 个步骤:

1) 根据输入及输出参数个数确定灰色神经网络结构和初始网络参数, 进而以网络参数个数为维数对个体进行编码; 2) 利用 CDSA 算法优化网络权值和阈值, 将预测误差作为适应度函数, 在训练集中对所构造的网络进行训练, 利用寻优得到的最优个体确定网络参数; 3) 输入测试集, 预测并输出目标威胁值. 算法流程如图 5 所示.




图5 算法流程

Step 1: 数据预处理. 对初始数据进行信息提取、归一化等操作, 为后续工作做准备.

Step 2: 确定网络结构及各层节点个数, 构建网络模型, 设定种群规模、迭代次数及相关变量参数.

Step 3: 初始化种群. 对操作对象即问题解集进行编码, 通常采取实数编码的方式, 由网络初始参数组成一个实数串, 每个实数串代表一个海豚个体, 实数串的位数即网络参数个数, 通过混沌搜索产生初始种群.

Step 4: 根据 DSA 算法, 依次完成种群的搜索、呼叫、应答和捕猎环节.

Step 5: 计算个体适应度值, 对种群分群.

Step 6: 计算种群适应度和聚集度, 判断种群是否

早熟,若早熟,则对最优解进行混沌映射.适应度函数由预测与期望之间的差值确定,即 $F_i = \hat{y}_i - \bar{y}_i$.

Step 7:判断算法是否满足迭代终止条件.若不满足,则转入Step 4,继续进行种群寻优;否则,输出最优个体,并依此确定网络参数.

灰色神经网络中,神经网络部分主要用于修正残差数据,但耗费大部分训练时间,在实际应用中可适当放宽神经网络训练的结束条件,减少迭代次数,以提高模型训练效率.

3 空中目标威胁评估模型及数据预处理

目标威胁评估是特定环境下的多因素NP难问题,各因素间具有非线性、强耦合等特点,而实战条件对系统实时性要求较高,需合理选取若干指标建立科学有效的评估模型^[14-15].基于防空作战目标威胁评估的特点,本文从威胁价值、威胁能力和威胁程度3个方面建立如图6所示的目标威胁评估框架,对威胁指标进行量化分析.




图6 目标威胁评估框架

3.1 威胁价值

各要地设施的重要程度不同,同一目标威胁到不同区域所形成的受胁价值也不等,被袭目标重要度越高,受胁价值越高,目标威胁度越大.参照要地重要度的评价方法,建立受胁价值函数

$$C_i = \frac{\ln\left(\prod_{j=1}^s C_{ij}\right) + 1}{\ln(10^s) + 1} = \frac{\sum_{j=1}^s \ln C_{ij} + 1}{\ln(10^s) + 1},$$

其中 C_{ij} 表示衡量我方设施 i 的受胁价值的第 j 个因素值.实际作战中,受胁价值通常由上级综合兵力部署、要地重要程度等因素后给出.

3.2 威胁能力

威胁能力是指目标突防能力及其突防后对我方目标的攻击能力,影响目标攻击能力的因素主要有目标类型和毁伤能力,而突防能力则与干扰能力直接相关.

1) 目标干扰能力.根据目标类型及电子干扰技术手段,可将目标干扰能力分为强、中、弱、无4个

等级,依次量化为0.8、0.6、0.4、0.1.

2) 目标类型.目标类型包括飞机和制导武器两大类.飞机类有轰炸机、歼击机和武装直升机等.预警机、侦察机等支援类飞机常处于防空体系防区外,威胁度较小,不予考虑.制导武器包括制导炸弹(Precision guided bomb, PGB)、战术弹道导弹(Tactical ballistic missile, TBM)、巡航导弹(Cruise missile, CM)、反辐射导弹(Anti-radiation missile, ARM)等.各类目标威胁隶属度如表1所示.

表1 目标威胁隶属度

目标类型	威胁隶属度	目标类型	威胁隶属度
轰炸机	0.80 ~ 0.85	制导炸弹	0.55 ~ 0.70
歼击机	0.60 ~ 0.70	TBM	0.85 ~ 1.00
武装直升机	0.30 ~ 0.35	巡航导弹	0.50 ~ 0.65
干扰机	0.10 ~ 0.20	反辐射导弹	0.75 ~ 0.85

3) 毁伤能力.毁伤能力表征了目标在不受体系对抗时可能对我方造成的毁伤程度.制导武器毁伤能力主要与自身攻击力有关,而敌机毁伤能力取决于机载武器的种类、数量及毁伤能力.本文在评价毁伤能力时,还考虑了我方受胁设施的生存力(Survivability),即可承受打击的能力.综合受胁目标的作用、抗毁能力等因素推理出目标毁伤率(Kill probability),形成表2所示的参数表,相关信息通过情报资料或统计方法获取.

表2 生存力与毁伤率参数

受胁设施	生存力/毁伤率			
	PGB	TBM	CM	ARM
T_1	s_{PGB}^1/k_{PGB}^1	s_{TBM}^1/k_{TBM}^1	s_{CM}^1/k_{CM}^1	s_{ARM}^1/k_{ARM}^1
T_2	s_{PGB}^2/k_{PGB}^2	s_{TBM}^2/k_{TBM}^2	s_{CM}^2/k_{CM}^2	s_{ARM}^2/k_{ARM}^2
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
T_n	s_{PGB}^n/k_{PGB}^n	s_{TBM}^n/k_{TBM}^n	s_{CM}^n/k_{CM}^n	s_{ARM}^n/k_{ARM}^n

毁伤能力通过毁伤率与我方设施生存力来表征,目标 i 对我方设施 T_j 的毁伤能力表示为

$$K_i^{T_j} = \sum_i \frac{k_i^j}{s_i^j} \in [0, 1].$$

3.3 威胁程度

目标距离、航路捷径、航路角通常能够反映目标的攻击意图,而航路捷径与距离、航路角相关距离又与目标速度和飞临时间相关.本文选取目标速度、飞临时间和航路角作为目标威胁度指标.

1) 目标速度.目标速度越大,威胁度越大,但速度过低时,目标会对防空系统的雷达扫描和跟踪造成影响,因此构造速度隶属度函数如下:

$$K(v) = \begin{cases} 1 - e^{-0.005|v|}, & v \geq 100; \\ 1 - e^{0.2|v|-20.5}, & 20 \leq v < 100. \end{cases}$$

2) 飞临时间. 飞临时间是指目标到达防空火力远界所需要的时间, 单位为min. 定义飞临时间隶属度函数为

$$K(t) = e^{-2 \times 10^{-6} t^2}.$$

3) 航路角. 目标的航路角是指目标速度在水平面的投影与敌我连线的夹角. 定义航路角隶属度函数为

$$K(\theta) = \begin{cases} e^{-|\theta|}, & \arcsin \frac{r}{2R} \leq |\theta| \leq \frac{\pi}{2}; \\ 0, & \text{Else.} \end{cases}$$

其中: r 为目标水平距离, R 为目标最小机动半径.

4 实验分析

4.1 实验设计

根据目标威胁评估框架, 目标威胁度由7组指标决定, 输入数据维数为7, 因此灰色神经网络为1-1-8-1结构, LC层7个节点分别对应输入受胁价值、目标类型、干扰能力、毁伤能力、目标速度、飞临时间、航路角数据, 输出即目标威胁预测值. 参数设置: 种群规模 $M = 40$, 最大迭代次数为100, $T = 3$, $T' = 1000$, $\text{speed} = 3$, $e = 4$, GNNM最大运行次数为200. 实验利用Matlab软件编程实现. 原始数据从某系统的目标威胁数据库中随机获取, 按目标类型分别选取目标数据200组作为训练集, 另外选取24组数据组成测试集. 部分测试集数据见表3.

表3 测试集

序号	目标类型	毁伤能力	速度/(m/s)	飞临时间/min	航向角/(°)	干扰能力	受胁价值	威胁值
1	轰炸机	0.921	450	15.4	9	强	0.64	0.679
2	轰炸机	0.797	360	22.5	16	中	0.35	0.596
3	歼击机	0.524	760	16.2	14	中	0.36	0.495
4	歼击机	0.675	580	10.4	17	弱	0.24	0.583
5	武装直升机	0.647	180	22.2	11	中	0.22	0.742
6	武装直升机	0.581	220	18.6	17	强	0.26	0.657
7	干扰机	0.456	360	19.2	12	强	0.23	0.503
8	干扰机	0.384	420	14.4	3	强	0.21	0.624
9	制导炸弹	0.526	300	0.6	11	无	0.14	0.315
10	制导炸弹	0.746	240	1.0	15	无	0.16	0.286
11	TBM	0.874	880	1.6	12	无	0.22	0.456
12	TBM	0.924	940	2.8	20	无	0.16	0.628
13	空地导弹	0.885	740	1.4	10	无	0.26	0.549
14	空地导弹	0.745	690	0.9	8	无	0.16	0.548
15	ARM	0.627	740	1.8	15	无	0.12	0.626
16	ARM	0.568	760	1.6	24	无	0.08	0.352

由于种群初始化是随机的, 实验中将算法运行10次以检验CDSA优化灰色神经网络在目标威胁评估中的稳定性和应用效果, 每次运行产生24个误差值, 通过预测误差检验算法优化性能. 另外, 实验还将灰色神经网络、DSA优化灰色神经网络和CDSA优化灰色神经网络分别在训练集中进行训练, 运行10次, 并用于对测试集中目标威胁度的预测评估, 将实验结果进行对比分析, 从而验证本文所提出方法的有效性和优越性.

4.2 结果分析

图7为实验得到的平均预测误差, 它直观地反映出不同方法之间预测精度的差别. 可以看出: DSA-GNNM的整体预测效果比GNNM有了明显改善; 而相比DSA-GNNM, 除样本1和样本7外, CDSA-GNNM对其他样本的评估都得到了优化. 从仿真结果看, CDSA-GNNM的性能比较稳定, 其预测精度最

高, 而GNNM的预测效果最差. 总体而言, 3种方法的预测精度从高到低依次为CDSA-GNNM > DSA-GNNM > GNNM.




图7 目标威胁评估误差

图8为DSA-GNNM和CDSA-GNNM的迭代曲线图. CDSA-GNNM在迭代速度上先快后慢, 更易收敛, 最终的优化效果得到了改善, 说明本文所提出的混沌海豚群算法在应用中是有效的.




图8 迭代曲线

5 结论

本文结合防空作战特点,将灰色神经网络用于空中目标威胁评估,并通过混沌海豚群算法进行优化,建立了混沌海豚群优化灰色神经网络的空中目标威胁评估模型.针对海豚群算法,提出了一种混沌搜索改进策略,通过混沌初始化、动态分群策略和早熟优化机制,进一步提高了算法的寻优能力和效率.根据空中来袭目标特性,充分考虑目标威胁度的影响机理,避免主观因素的影响,提出了一种综合威胁价值、威胁能力和威胁程度的空中目标威胁评估框架.将混沌海豚群算法与灰色神经网络结合,利用最优解搜索完成网络初始值的寻优,从而建立基于混沌海豚群算法优化的灰色神经网络模型,实现了对空中目标威胁度的有效预测评估.如何实现评估模型与指挥控制系统的融合是后续研究的重点.

参考文献(References)

- [1] 刘敬蜀,姜文志,雷宇曜,等. 动态火力接入下要地防空作战目标威胁评估[J]. 北京航空航天大学学报, 2016, 42(7): 1432-1440.
(Liu J S, Jiang W Z, Lei Y Y, et al. Threat evaluation of air-targets for key positions air-defense under dynamic fireaccess[J]. J of Beijing University of Aeronautics and Astronautics, 2016, 42(7): 1432-1440.)
- [2] Wang X X, Yu Y S. Efficiency evaluation of command information system based on cloud model[C]. Int Conf on Intelligent Human-machine Systems and Cybernetics. Washington, 2014: 148-151.
- [3] Tomas J, Tomas F, Wang W J, et al. Bayesian truthing as experimental verification of C4ISR sensors[C]. Proc of SPIE. Baltimore, 2015: 1-12.
- [4] Seckin U, Tuncay G. Threat evaluation using analytic network process[J]. IFAC Papers On Line, 2015, 48(3): 8-13.
- [5] 李姜,郭立红. 基于改进支持向量机的目标威胁估计[J]. 光学精密工程, 2014, 22(5): 1354-1362.
(Li J, Guo L H. Target threat assessment using improved SVM[J]. Optics and Precision Engineering, 2014, 22(5): 1354-1362.)
- [6] 刘海波,王和平,沈立顶. 基于SAPSO优化灰色神经网络

- 的空中目标威胁估计[J]. 西北工业大学学报, 2016, 34(1): 25-32.
- (Liu H B, Wang H P, Shen L X. Target threat assessment using SAPSO and grey neural network[J]. J of Northwestern Polytechnical University, 2016, 34(1): 25-32.)
- [7] Lee H, Choi B J, Kim C O, et al. Threat evaluation of enemy air fighters via neural network-based markov chain modeling[J]. Knowledge-Based Systems, 2017, 116: 49-57.
- [8] 武华,苏秀琴. 基于群广义直觉模糊软集的空袭目标威胁评估方法[J]. 控制与决策, 2015, 30(8): 1462-1468.
(Wu H, Su X Q. Threat assessment of aerial targets based on group generalized intuitionistic fuzzy soft sets[J]. Control and Decision, 2015, 30(8): 1462-1468.)
- [9] 陈军,徐嘉,高晓光. 基于ABFCM模型框架的UCAV自主攻击决策[J]. 系统工程与电子技术, 2017, 39(3): 549-556.
(Chen J, Xu J, Gao X G. Autonomous attack decision-making of UCAV based on ABFCM model framework[J]. Systems Engineering and Electronics, 2017, 39(3): 549-556.)
- [10] 雷晓彝,李曙伟,阳杰,等. 基于小波包-灰色神经网络的机电作动系统故障预测[J]. 计算机测量与控制, 2014, 22(6): 1704-1707.
(Lei X B, Li S W, Yang J, et al. Fault prediction of electromechanical actuating system based on wavelet packet-gray neural network[J]. Computer Measurement & Control, 2014, 22(6): 1704-1707.)
- [11] Wu T Q, Yao M, Yan J H. Dolphin swarm algorithm[J]. Frontiers of Information Technology & Electronic Engineering, 2016, 17(8): 717-729.
- [12] Yang B, Liao X F. Period analysis of the Logistic map for the finite field[J]. Science China Information Sciences, 2017, 60(2): 1-15.
- [13] 易怀军,刘宁,张相炎,等. 基于优化的非等间隔灰色理论和BP神经网络的身管磨损量预测[J]. 兵工学报, 2016, 37(12): 2220-2225.
(Yi H J, Liu N, Zhang X Y, et al. Prediction of gun barrel wear based on improved non-equal interval grey model and BP neural network[J]. Acta Armamentarii, 2016, 37(12): 2220-2225.)
- [14] 史小斌,顾红,苏卫民,等. 地面侦察雷达目标威胁度评估方法研究[J]. 兵工学报, 2015, 36(6): 1128-1135.
(Shi X B, Gu H, Su W M, et al. Study of target threat assessment for ground surveillance radar[J]. Acta Armamentarii, 2015, 36(6): 1128-1135.)
- [15] 张浩为,谢军伟,盛川. 综合优先级规划下的相控阵雷达自适应调度方法[J]. 兵工学报, 2016, 37(11): 2163-2169.
(Zhang H W, Xie J W, Sheng C. Adaptive Scheduling Algorithm over Comprehensive Priority for Phased Array Radar[J]. Acta Armamentarii, 2016, 37(11): 2163-2169.)

(责任编辑: 齐 霁)