

引用格式:陈侠,刘子龙.基于粒子群优化模糊小波网络的目标威胁评估[J].电光与控制,2019,26(3):30-34,111. CHEN X, LIU Z L. Evaluation of aerial target threat based on fuzzy wavelet neural network and particle swarm optimization[J]. Electronics Optics & Control, 2019, 26(3):30-34, 111.

基于粒子群优化模糊小波网络的目标威胁评估

陈 侠, 刘子龙

(沈阳航空航天大学,沈阳 110136)

摘要: 主要对不确定性环境下的空中目标威胁评估问题进行研究。首先通过模糊神经网络处理信息不确定问题,在获取威胁目标信息较少的环境下,使用小波神经网络增强网络自学习能力,并分析威胁因素,创建不确定性环境下的模糊小波神经网络(FWNN),实现对目标威胁的评估;然后针对初始参数的不确定性问题,采用粒子群优化算法和BP算法更新每个模糊规则后件部分的参数,以达到提高评估效果的目的。仿真结果表明,与模糊小波神经网络相比,该算法提高系统的稳定性,加快收敛速度,增强预测精度。

关键词: 目标威胁评估; 粒子群算法; 小波神经网络; 模糊小波神经网络; BP 算法

中图分类号: V279 文献标志码: A doi:10.3969/j.issn.1671-637X.2019.03.007

Evaluation of Aerial Target Threat Based on Fuzzy Wavelet Neural Network and Particle Swarm Optimization

CHEN Xia, LIU Zi-long

(Shenyang University of Aerospace, Shenyang 110136, China)

Abstract: This paper focuses on threat assessment of aerial target under uncertain environment. First, the problem of uncertain information is solved by using fuzzy neural networks. In the environment with less threat target information, the wavelet neural network is used to enhance the self-learning ability of the network and the threat factors are analyzed. The Fuzzy Wavelet Neural Network (FWNN) in the uncertain environment is established to achieve the target threat evaluation. For the uncertainty of the initial parameters, the consequent parameters of each fuzzy rule are updated by using the particle swarm optimization algorithm and the BP algorithm to achieve the purpose of improving the evaluation effect. The simulation results show that: Compared with the fuzzy wavelet neural network, the stability of the system is improved, the convergence speed is accelerated, and the prediction accuracy is enhanced.

Key words: target threat assessment; particle swarm algorithm; wavelet neural network; fuzzy wavelet neural network; back-propagation algorithm

0 引言

目标威胁评估是空战决策系统的核心技术之一,是复杂态势信息融合的一个关键环节,其评价结论对目标火力分配和战术决策影响深远。目前,目标威胁评估的常用方法有直觉模糊集^[1-2]、贝叶斯推理^[3-4]、优劣解距离法^[5]、计划识别^[6]等。这些方法各有优缺点,可用于不同的环境,但以上方法在很大程度上往往

依赖专家的经验获取常权向量,从而在进行目标威胁估计时的行为过于主观。随着智能技术的日益完善,神经网络在评估领域已经取得了重大突破。文献[7]将优化BP(Back-Propagation)神经网络应用于空战目标威胁评估,取得了良好的预测结果。但是,随着对BP神经网络的不断研究,学者发现它也存在着一些不可避免的缺陷,如过拟合、易陷入局部极值等。

小波神经网络(Wavelet Neural Network, WNN)已经广泛应用于多个领域^[8-11]。文献[8]运用小波神经网络对电力信号系统进行诊断,得到良好的拟合效果。然而,小波神经网络对确定性输入具有很好的分析能力,如果输入属于不确定性信息,则网络的性能就有所欠缺。模糊神经网络如今已经应用在很多领域,诸如预

收稿日期:2018-04-02 修回日期:2018-11-28
基金项目:国家自然科学基金(61074159);航空科学基金(2016ZC54011);辽宁省自然科学基金(2015020063)
作者简介:陈 侠(1962—),女,辽宁新民人,博士,教授,研究方向为无人机任务规划。

测、任务分配等^[12-13],该网络的优点是可以解决输入具有模糊性的实际问题,然而其缺点同样明显,模糊语言总是依赖专家经验,并且网络的抗扰动能力较差等。

目前关于模糊小波神经网络研究已经引起了多个领域的重视,特别是在控制与决策领域^[14]取得了长足的进步。

本文的研究对象是针对复杂战场环境下无人机多种不规律输入问题的目标威胁评估。针对现代战争中威胁因素形式多变、复杂的特点,使用模糊小波神经网络解决评估问题。网络参数的初值往往是随机产生的,具有精度差的缺陷,为了获得较好的网络初始参数,本文提出了粒子群优化算法(Particle Swarm Optimization, PSO)优化网络模型选取较优的初始参数,使用BP算法更新每个模糊规则后件的参数,实现对目标威胁的评估。仿真实验表明,相比于模糊小波神经网络,粒子群优化模糊小波神经网络提高了系统的稳定性,加快了收敛速度,并提高了系统的泛化性能。

1 模糊神经网络模型

图1 所示为模糊神经网络模型。

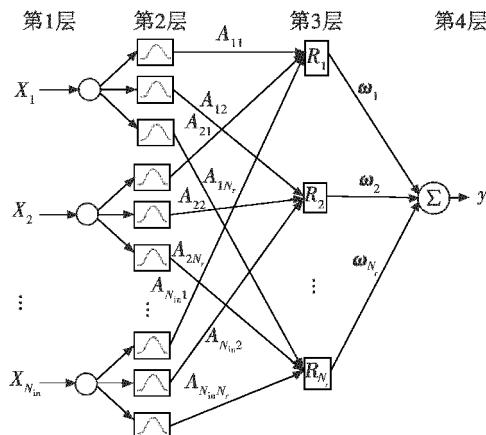


图1 模糊神经网络结构

Fig. 1 Structure of fuzzy neural network

图1中有 N_{in} 个输入,1个输出, $N_{in} \times N_r$ 个隶属度函数, N_r 个模糊规则。简单介绍网络模型的构成:第1层对应无人机不同的威胁因素,并将这些因素作为网络的输入;第2层将输入做正态分布处理,为模糊隶属度函数;第3层将处理的结果进行取小运算,为模糊规则层;第4层输出网络运算的结果层。将神经网络与TSK模糊模型相结合,目的是增加模型的精度同时也提高了系统的灵活性。假设有 N_r 个模糊IF-THEN规则,即 R_j :IF x_1 is A_{1j} AND x_2 is A_{2j} AND ... AND x_i is A_{ij} THEN $y_j = \sum_{j=1}^{N_r} \omega_j \cdot \mu_j$ 。其中: x_i 表示网络的第*i*个输入($i = 1: N_{in}$); A_{ij} 是一种经过模糊隶属度函数 $\mu_{A_{ij}}(x_i)$ ($j = 1: N_r$)处理的模糊语

言; ω_j 代表第3层与第4层之间重要程度,即权重向量; μ_j 是模糊层的输出; y_j 是网络最终的输出。

模糊理论中隶属度函数多种多样,比如三角形、梯形、Gaussian等隶属度函数,由于 Gaussian 形隶属度函数可以保持输入的原始特性,使得训练数据更“真实”,因此,在隶属度层选取 Gaussian 函数,其表达式为

$$\mu_{A_{ij}}(x_i) = \exp\left(-\frac{(x_i - c_{ij})^2}{\sigma_{ij}^2}\right) \quad \forall i = 1: N_{in}, j = 1: N_r \quad (1)$$

式中: c_{ij} , σ_{ij} 分别代表第*j*个规则的中心参数和伸缩参数。

第3层每个节点代表一个模糊规则 R 。每个节点的输出可以表示为

$$\mu_j(x) = \prod_i \mu_{A_{ij}}(x_i) \quad i = 1: N_{in}, j = 1: N_r \quad (2)$$

式中: \prod 代表逻辑“与”操作,即取小运算。

第4层输出结果,得到输出式为

$$y_j = \sum_{j=1}^{N_r} \omega_j \cdot \mu_j(x) \quad (3)$$

2 小波神经网络模型

小波神经网络的特点是将隐含层神经元中不具有局部特性的 sigmoid 激活函数换成小波函数,保持神经元的活跃性,使得参数可以跳出局部极小值,其网络结构见图2,由 N_{in} 个输入、1个输出、 N_w 个隐层神经元组成。

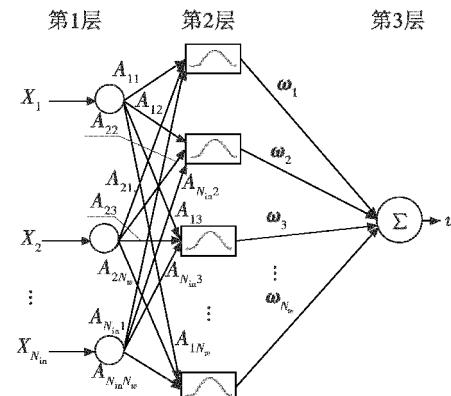


图2 小波神经网络结构

Fig. 2 Structure of wavelet neural network

第1层为输入层,直接传递到第2层小波层。小波族的分类目前有 Morlet 小波、Gaussian 小波、墨西哥帽小波等形式。由于 Gaussian 函数的一阶偏导数 $\varphi(x) = x \cdot \exp(-0.5x^2)$ 能较好地跟踪数据特征,所以将导数选为母小波函数。选定母小波之后,将数据做伸缩和平移处理,并放入隐含层作为激活函数,表达式为

$$\begin{aligned} \varphi_r(z_r) &= \sum_{l=1}^{N_w} z_r \exp(-0.5 \cdot z_r^2) \\ \forall z_r &= \left(\frac{x_l - t_r}{d_r}\right) \quad r = 1: N_w, l = 1: N_{in} \end{aligned} \quad (4)$$

式中: t_r 表示小波分解中的平移系数; d_r 表示伸缩系数,下标 rl 表示第 l 个输入对应第 r 个神经元。第3层输出层的输出为

$$v = \sum_{r=1}^{N_r} \omega_r \cdot \varphi_r \quad (5)$$

式中: ω_r 是连接隐含层和输出层的权值。

3 模糊小波神经网络模型的构建

针对现代战争中威胁因素形式多变、复杂的特点,使用模糊小波神经网络解决评估问题。应用BP算法对参数进行实时选择,使得前向件参数具有自适应特性,符合函数特征,体现更好的评估效果,同时可以迅速地适应战场环境因素复杂多变的情况,从而精确地对空中目标威胁进行评估。模糊小波神经网络结构如图3所示。

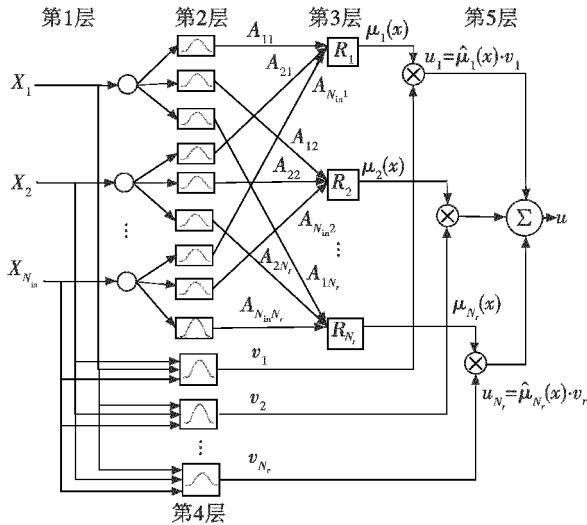


图3 模糊小波神经网络结构

Fig. 3 Structure of fuzzy wavelet neural network

第1层为输入层,第2层为隶属度函数层,由式(1)计算出本层节点的输出,第3层为模糊规则层,由式(2)计算出本层节点的输出值,第4层是小波函数层,将第1层输入数据代入式(4)和式(5)中,计算出本层节点的输出值,在第5层(输出层)中,用经过小波神经网络处理的输出数据与网络的第3层(模糊规则层)节点输出相乘,表达式如下

$$u_j(x) = \hat{\mu}_j(x) \cdot v_j \quad j = 1:N_r \quad (6)$$

式中: $\hat{\mu}_j(x) = \frac{\mu_j(x)}{\sum_{j=1}^{N_r} \mu_j(x)}$ 。由式(6)可知, v_j 表示第 j 个小波函数的输出值。

最终得到输出层的值,计算结果为

$$u(k) = \sum_{j=1}^{N_r} \hat{\mu}_j(x) \cdot v_j = \sum_{j=1}^{N_r} u_j \quad (7)$$

模糊小波神经网络的参数在网络训练的过程中对

网络的性能具有十分关键的影响,其初始值使用粒子群算法选取得到,之后使用BP算法对网络参数进行更新。

误差函数为

$$e(k) = \frac{1}{2} \sum_{k=1}^{500} (u_q(k) - u(k))^2 \quad (8)$$

式中: u_q 代表网络实际的输出值; u 代表网络的输出值; k 代表迭代的次数。通过调整网络的参数,主要的目的是使得误差函数 $e(k)$ 达到最小,从而具有更好的精确性。在网络训练过程中采用基于BP学习算法不断更新参数 c, σ, t, d, ω ,为了使网络的输出更加接近实际的预测值,不断地调整这些参数,选取最优值作为预测部分的参数值。常用偏导数公式如下

$$\frac{\partial e(k)}{\partial u(k)} = u_q(k) - u(k) \quad (9)$$

$$\frac{\partial u(k)}{\partial v(k)} = \hat{\mu}_j(k) = \frac{\mu_j(x)}{\sum_{j=1}^{N_r} \mu_j(x)} \quad (10)$$

$$\frac{\partial \varphi_r(k)}{\partial z(k)} = \exp(-0.5z^2) - z^2 \cdot \exp(-0.5z^2) \quad (11)$$

$$\frac{\partial z(k)}{\partial d(k)} = \frac{-(x(k) - t(k))}{d^2(k)} \quad (12)$$

$$\frac{\partial z(k)}{\partial t(k)} = -\frac{1}{d(k)} \quad (13)$$

$$\frac{\partial u(k)}{\partial \hat{\mu}(k)} = v(k) = \omega_r \cdot \varphi_r(k) \quad (14)$$

$$\frac{\partial \hat{\mu}(k)}{\partial \mu(k)} = \frac{1}{\sum_{j=1}^{N_r} \mu_j(k)} \quad (15)$$

$$\frac{\partial \mu(k)}{\partial \sigma(k)} = \mu_{A_{ij}} \cdot \left(\frac{x(k) - c(k)}{\sigma} \right)^2 \quad (16)$$

$$\frac{\partial \mu(k)}{\partial c(k)} = \frac{2\mu_{A_{ij}}}{\sigma} \circ \quad (17)$$

参数更新公式如下。由式(9)、式(10)得到

$$\begin{aligned} \frac{\partial e(k)}{\partial \omega(k)} &= \frac{\partial e(k)}{\partial u(k)} \cdot \frac{\partial u(k)}{\partial v(k)} \cdot \frac{\partial v(k)}{\partial \omega(k)} = \\ &= (u_q(k) - u(k)) \cdot \hat{\mu}_j(k) \cdot \varphi_r(k) \end{aligned} \quad (18)$$

由式(9)~式(12)得到

$$\begin{aligned} \frac{\partial e(k)}{\partial d(k)} &= \\ &= \frac{\omega_r(k) \cdot (u_q(k) - u(k)) \cdot \mu_j(x) \cdot (\exp(-0.5z^2) - z^2 \cdot \exp(-0.5z^2))}{\sum_{j=1}^{N_r} \mu_j(x)} \\ &- \frac{(x(k) - t(k))}{d^2(k)} \end{aligned} \quad (19)$$

由式(9)、式(10)、式(11)、式(13)得到

$$\frac{\partial e(k)}{\partial t(k)} = \frac{\omega_r(k) \cdot (u_q(k) - u(k)) \cdot \mu_j(x)}{d(k) \cdot \sum_{j=1}^{N_r} \mu_j(x)} \quad (19)$$

$$(\exp(-0.5z^2) - z^2 \cdot \exp(-0.5z^2))。 \quad (20)$$

由式(9)、式(14)~式(16)得到

$$\frac{\partial e(k)}{\partial \sigma(k)} = \frac{(u_g(k) - u(k)) \cdot \omega_r \cdot \varphi_r(k)}{\sum_{j=1}^{N_r} \mu_j(k)} \cdot \mu_{A_{ij}} \cdot \left(\frac{x(k) - c(k)}{\sigma} \right)^2。 \quad (21)$$

由式(9)、式(14)、式(15)、式(17)得到

$$\frac{\partial e(k)}{\partial c(k)} = \frac{(u_g(k) - u(k)) \cdot \omega_r \cdot \varphi_r(k)}{\sum_{j=1}^{N_r} \mu_j(k)} \cdot \frac{2\mu_{A_{ij}}}{\sigma}。 \quad (22)$$

4 粒子群优化模糊小波网络参数的算法

PSO 算法是一种群体算法,最初是仿生鸟类飞行轨迹,是一种启发式算法。及至多维空间,搜索空间中的一只鸟代表优化问题的解,根据自身的经验动态地调整速度。粒子群优化算法首先会随机初始化一个种群,用粒子代表一只鸟,每个粒子根据经验判断自己的下一步位置,跟踪个体极值 p_{best} 和全局极值 g_{best} 更新自己的位置和速度,直至找到最优解。对每个粒子依据适应度值可判别优良程度,且代表被优化问题的一个潜在解。

假设每只鸟为一个质点,目标搜索空间的维数为 D ,种群规模为 N , $X_i = (x_{i1}, x_{i2}, \dots, x_{in})$ 和 $V_i = (v_{i1}, v_{i2}, \dots, v_{in})$ 分别为粒子 i 的位置和速度, $P_i = (p_{i1}, p_{i2}, \dots, p_{in})$ 为粒子 i 的个体极值, P_g 为全局极值。每个粒子都有一个适应度值,当粒子更新到第 t 代时,粒子的速度和位置更新算式为

$$v_{ij}(t+1) = \omega v_{ij}(t) + c_1 r_1 [p_{ij}(t) - x_{ij}(t)] + c_2 r_2 [p_{gi}(t) - x_{ij}(t)] \quad (23)$$

$$x_{ij}(t+1) = x_{ij}(t) + v_{ij}(t+1) \quad (24)$$

式中: c_1 和 c_2 为学习因子,一般取正整数,分别代表粒子的自学习和社会学习部分; r_1 和 r_2 是 $[0,1]$ 上服从均匀分布的随机数; ω 为权重,较大的 ω 可以有效地跳出局部极值,较小的 ω 可以进行局部寻优,使算法收敛加快。在本文仿真实验中取 $\omega=0.75$ 。

搜索时,PSO 算法不依靠外部条件,仅取决于自身适应度函数,种群中每个粒子根据适应度值进行搜寻。因此选择合适的适应度函数极其关键,这决定了算法的收敛速度和最优解,适应度函数为

$$e(k) = \frac{1}{2} \sum_{i=1}^{500} (u_g(k) - u(k))^2。 \quad (25)$$

具体 PSO 算法步骤如下。

1) 初始化粒子群,包含粒子的速度、位置、个体极值和全局极值。

2) 对群体中每一个粒子的 P_i 进行下述操作:

① 根据式(23)和式(24)改变粒子 P_i 的速度和位移;

- ② 计算粒子 P_i 的适应值;
- ③ 如果适应值优于 p_{best} ,则更新 p_{best} 为粒子的当前位置;
- ④ 如果适应值优于 g_{best} ,则更新 g_{best} 为粒子的当前位置。
- 3) 最终判断粒子群是否符合终止条件,若满足则跳到 4),否则,执行 2)。
- 4) 输出 g_{best} 的信息,算法结束。

5 目标威胁评估的因素分析

本文主要根据现代战场上无人机的空防态势来建立目标威胁评估模型,采用包括目标种类、目标航向角、无人机速度、干扰能力、无人机高度和目标距离在内的 6 个主要评价指标建立 PSO-FWNN 目标威胁评估模型。

本文将目标威胁数据库^[7]中的 310 组数据作为实验数据,部分数据在表 1 中表明。本文分类处理这些数据,将其中 300 组作为训练集,将其中的 10 组数据作为实验集,PSO-FWNN 模型需要对输入威胁因素进行预处理,对各威胁因素归一化,取值在 $[-1,1]$ 。

表 1 部分目标威胁数据库数据

Table 1 Some data in target threat database

序号	目标类型	目标速度/ $(m \cdot s^{-1})$	目标航向角/ $(^\circ)$	干扰能力	高度	距离/ km	威胁值
1	TBM	510	140	中	高	370	0.5222
2	TBM	560	80	强	中	170	0.5838
3	TBM	640	120	中	低	290	0.6475
4	TBM	460	90	强	低	310	0.5853
5	小型机	610	60	中	高	170	0.6863
6	小型机	660	90	中	中	210	0.7435
7	小型机	710	130	强	低	330	0.7346
8	小型机	760	160	中	超低	410	0.7551
9	直升机	90	30	中	低	220	0.3621
10	直升机	93	60	无	中	190	0.3517
11	直升机	95	110	弱	低	220	0.3771
12	直升机	98	150	无	超低	330	0.3582

1) 目标种类分 5 大类: 导弹、直升机、小型目标、大型目标和战术弹道导弹(TBM)。采用 MILLER 的量化原理对其量化,得到对应的隶属度 μ 值分别为 0.1, 0.2, 0.3, 0.4, 0.5。

2) 目标干扰能力分为很强、强、中、弱、很弱 5 个等级,对应量化为 0.9, 0.7, 0.5, 0.3, 0.1。

3) 目标航向角在 $0^\circ \sim 360^\circ$ 中,按照 36° 进行划分,对应 μ 值分别为 0.9, 0.8, 0.7, 0.6, 0.5, 0.4, 0.3, 0.2, 0.1。

4) 目标高度分为 4 个等级。按照 μ 分别是 0.2, 0.4, 0.6, 0.8, 对应是高、中、低、超低。

5) 目标距离,距离的远近表明了敌机的打击意图。目标距离越远,威胁程度越小,目标距离的隶属度值为

$$\mu_1 = \frac{\max\{l_i\} - l_i}{\max\{l_i\} - \min\{l_i\}}。 \quad (26)$$

6) 目标速度,空袭目标速度影响着防空武器的反应时间。速度越快,威胁程度越大,目标速度的隶属度值为

$$\mu_v = \frac{v_i - \max\{v_i\}}{\max\{v_i\} - \min\{v_i\}} \quad (27)$$

6 基于 PSO-FWNN 的目标威胁评估仿真实验

输入/输出数据的维数决定了 PSO-FWNN 模型的结构。无人机目标威胁评估输入有 6 类输入变量,输出为威胁程度,所以模糊小波神经网络结构为 $6 - 6 \times 5 - 5 - 5 - 1$,即第 1 层为网络输入层,输入分别是无人机类型、目标干扰能力、目标航向角、无人机速度、无人机高度、目标距离共 6 个威胁指标,第 2 层隶属度层有 6×5 个节点,第 3 层模糊规则层和第 4 层小波层各有 5 个节点,最后一层为目标威胁值。将粒子群优化之后得到的参数作为初始参数代入模糊小波神经网络。

本文分别采用 PSO-FWNN 和 FWNN 对空中目标威胁评估进行建模仿真,两种算法的仿真实验结果如图 4 所示,通过对两种网络模型的评估值与实际值的仿真对比,得到图 5 所示的预测绝对误差曲线和图 6 所示的误差百分比曲线。

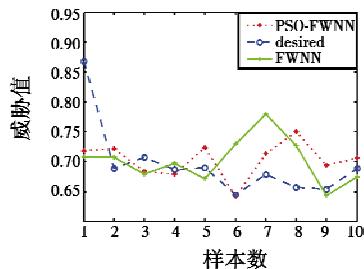


图 4 仿真结果

Fig. 4 Simulation results

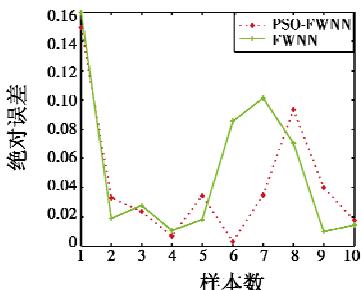


图 5 PSO-FWNN 和 FWNN 的绝对误差

Fig. 5 The absolute error of PSO-FWNN and FWNN

经过对图 5 的分析发现,PSO-FWNN 模型预测值与实际的威胁值的误差比 FWNN 的误差小。由此推断,PSO-FWNN 模型得到的结论较为精确,误差值较小,抗干扰能力较强。经过对表 2 输出误差值求和可知,粒子群优化模糊小波神经网络的绝对误差和为

0.4365,模糊小波神经网络的绝对误差和为 0.5160。

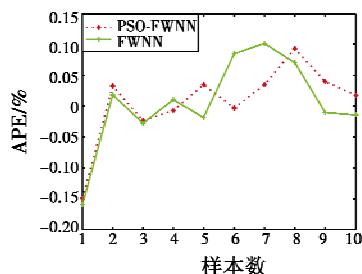


图 6 PSO-FWNN 和 FWNN 误差百分比

Fig. 6 The error percentage of PSO-FWNN and FWNN

表 2 两种模型的仿真结果和误差分析

Table 2 Error results and simulation analysis of two models

样本点	测试值	PSO-FWNN	FWNN	PSO-FWNN 的误差	FWNN 的误差
1	0.8681	0.7184	0.7083	0.1497	0.1598
2	0.6883	0.7212	0.7071	0.0329	0.0188
3	0.7074	0.6835	0.6794	0.0239	0.0280
4	0.6862	0.6796	0.6965	0.0066	0.0103
5	0.6891	0.7236	0.6709	0.0345	0.0182
6	0.6447	0.6416	0.7298	0.0031	0.0851
7	0.6780	0.7127	0.7794	0.0347	0.1014
8	0.6564	0.7498	0.7266	0.0934	0.0702
9	0.6539	0.6941	0.6438	0.0402	0.0101
10	0.6887	0.7062	0.6746	0.0175	0.0141

仿真结果表明:PSO-FWNN 算法具有较好的收敛性和准确度,对空中威胁估计结果优于 FWNN,预测结果较准,并且趋于真实威胁,从而验证了 PSO-FWNN 评估模型的合理性,可以适用于空中目标威胁评估预测。

7 结束语

空中目标威胁评估在现代战场上具有显著的作用,是信息融合的关键问题之一,考虑目标威胁估计因素具有诸多不确定性,模糊神经网络可以有效解决不确定问题,结合小波神经网络,采用模糊映射的方法建立威胁因素的评价集,建立新型的模糊小波神经网络,针对前人对网络初始参数随机产生的缺点,本文采用粒子群算法优化网络参数,选取最优值作为初始参数,通过 BP 算法实时改变网络前后的参数,并分析目标威胁的几个主要威胁指标和目标威胁度之间关系,提出了基于粒子群优化模糊小波神经网络来解决目标威胁评估。经过仿真实验可得:本文提出的粒子群优化模糊小波神经网络算法可应用于空中目标威胁评估,模糊集对不确定因素具有良好的适应性,其预测精度优于模糊小波神经网络,表明了网络的优良性能,预测结果更接近真实值,可以作为今后空中目标威胁评估的有效方法。

(下转第 111 页)

表2 倾转三旋翼无人机转动惯量关键参数

Table 2 Key parameters of three-axis inertia $\text{kg} \cdot \text{m}^2$

关键参数	J_{xx}	关键参数	J_{xx}
J_{x0}	1.8180	K_{J1}	0.00029270
J_{y0}	1.7990	K_{J2}	0.00040500
J_{z0}	0.1249	K_{J3}	0.00007167

4 结论

本文针对倾转三旋翼无人机在倾转过程中,无人机由于发动机短舱角变化引起的飞行器重心位置以及各轴转动惯量的变化建立了适当的数学模型,该模型可为无人机全过程飞行模式的数学建模提供理论依据,为实现无人机全过程飞行精确控制奠定理论基础。

参 考 文 献

- [1] 张飞,路平,江涛,等.基于模糊控制的倾转三旋翼无人机过度模式操纵策略研究[J].电光与控制,2018,25(4):1-6.
- [2] 陈琦,江涛,史凤鸣,等.倾转三旋翼无人机过度模式走廊曲线研究[J].电光与控制,2017,24(3):24-27.
- [3] 陈琦,江涛,蔚建斌,等.倾转三旋翼无人机关键技术

(上接第34页)

参 考 文 献

- [4] NOTARSTEFANO G, HAUSER J. Modeling and dynamic exploration of a tilt-rotor VTOL aircraft [C]//The 8th IFAC Symposium on Nonlinear Control Systems, Bologna, 2010:119-124.
- [5] BOLKCOM C. V-22 osprey tilt-rotor aircraft [R]. Washington:CRS Report for Congress, 2004.
- [6] 陈坤,史志伟,孙加亮.倾转三旋翼飞行器地面效应风洞试验[J].航空学报,2015,36(9):2884-2891.
- [7] 唐亮,徐庆九.海军倾转旋翼无人机技术和发展优势综述[J].科技资讯,2012(28):73-76.
- [8] 薛立鹏.倾转旋翼气动/动力学多学科优化设计研究[D].南京:南京航空航天大学,2011.
- [9] 王超.大尺寸飞行器质量特性测量关键技术研究[D].哈尔滨:哈尔滨工业大学,2014.
- [10] 徐小方,张华.飞行器转动惯量测量方法研究[J].科学技术与工程,2009,9(6):1653-1660.
- [11] 唐文彦,李慧鹏,张富春.扭摆法测量飞行体转动惯量[J].南京理工大学学报,2008,32(2):69-72.
- [12] 曹芸芸.倾转旋翼飞行器飞行动力学数学建模方法研究[D].南京:南京航空航天大学,2012.
- [13] 科学院长春光学精密机械与物理研究所,2013.
- [14] BODYANSKIY Y, DOLOTOROV A, VYNOKUROVA O, et al. Evolving spiking wavelet-neuro-fuzzy self-learning system [J]. Applied Soft Computing, 2014, 14(6):252-258.
- [15] HOU M Z, HAN X L. The multidimensional function approximation based on constructive wavelet RBF neural network[J]. Applied Soft Computing, 2011, 11(2):2173-2177.
- [16] JAMIL M, KALAM A, ANSARI A Q, et al. Generalized neural network and wavelet transform based approach for fault location estimation of a transmission line[J]. Applied Soft Computing, 2014, 14(6):322-332.
- [17] BAYRAM D, SEKER S. Wavelet based neuro-detector for low frequencies of vibration signals in electric motors [J]. Applied Soft Computing, 2013, 13(5):2683-2691.
- [18] 陆莹,李启明,周志鹏.基于模糊贝叶斯网络的地铁运营安全风险预测[J].东南大学学报:自然科学版,2010,40(5):1110-1114.
- [19] 陈夏冰,刘国栋.基于模糊神经网络Sarsa学习的多机器人任务分配[J].计算机应用与软件,2012,29(12):203-205,222.
- [20] ZHANG P, WANG H. Fuzzy wavelet neural networks for city electric energy consumption forecasting [J]. Energy Procedia, 2012, 17 (Part B):1332-1338.