

基于 GA-SLFRWNN 的空中目标威胁评估

陈侠, 刘子龙, 梁红利

(沈阳航空航天大学 自动化学院, 辽宁 沈阳 100136)

摘要:针对空战中目标威胁评估系统非线性、评估难度大且富含不确定信息的问题,研究了基于遗传算法优化模糊递归小波神经网络(single-hidden-layer fuzzy recurrent wavelet neural network optimized by genetic algorithm, GA-SLFRWNN)的目标威胁评估方法。首先通过分析威胁评估的影响因素及其信息的模糊性,将RWNN嵌入FNN的后件部分,以实现增强自学习能力的目的,然后采用GA对模型初始参数进行优化选取,并提出了基于李雅普诺夫理论的最优学习率。仿真实验表明:相比于FNN和FRWNN,该算法提高了系统的稳定性,加快了收敛速度,增强了预测精度。

关键词:目标威胁评估;模糊神经网络;模糊递归小波神经网络;遗传算法;最优学习率

中图分类号:V279

文献标志码:A

文章编号:1000-2758(2019)02-0424-09

随着战争中信息化的飞速发展,实时而准确地评估目标威胁,不仅为空战决策提供科学的决策依据,而且能够提高杀伤概率,因而研究目标威胁评估问题具有重要的理论和实际意义。针对空战中目标威胁评估系统非线性、评估难度大且富含不确定信息的问题,建立有效的评估威胁系统是很困难的。目前关于威胁评估模型及方法已经得到了广泛的研究。主要技术为:直觉模糊集^[1-4]、贝叶斯推理^[5-6]、多属性决策法^[7]、优劣解距离法^[8]、计划识别^[9]等。上述方法在很大程度上是依据专家经验确定威胁指标权重,具有较强的主观性,很难精确映照出威胁因素间的复杂非线性函数。在预测领域,神经网络凭借良好的自学习、自组织能力得到了广泛的应用^[10-12]。文献[10]运用优化的BP(back-propagation)神经网络对目标评估问题进行分析,表明了神经网络解决评估问题的有效性。但是,BP神经网络存在易陷入局部极值、过学习以及泛化性能差等问题。文献[12]研究了基于模糊控制系统的稳定性问题,文献[11]采用模糊推理系统结合BP神经网络对空中威胁进行了研究,其优点在于可以解决目标威胁环境中存在的模糊及不确定的问题。虽然模糊神经网络(fuzzy neural network, FNN)已经

成功地应用于许多复杂问题,但依然有2个缺点:①模糊神经网络存在着依赖先验知识、抗干扰性差、推广能力不足等问题;②神经网络的性能往往取决于网络参数的选取,因此对于初始参数的选取就显得至关重要。为了解决上述2个问题,本文应用单隐层模糊递归小波神经网络对目标威胁评估模型进行建模。SLFRWNN是将递归小波神经网络放入模糊神经网络的后件部分用于存储网络先前数据,相比于模糊神经网络,新模型能增强复杂系统的计算能力和泛化能力。遗传算法是一种用于对连续搜索空间进行智能寻优、二进制编码表示的优化技术,具有搜索速度快、效率高等特点。因此,为了提高神经网络的性能,采用遗传算法对网络的初始参数进行优化选取。在参数优化过程中,梯度下降法中的学习率选取往往影响网络的收敛速度,以往常常采用固定学习率对参数进行更新,通常依据专家经验进行选取,很难找到一个较好的学习率。本文采用一种自适应学习率,快速修正参数,使网络输出不断逼近期望输出,仿真实验表明:相比于FNN和FRWNN,该算法提高了系统的稳定性,加快了收敛速度,增强了预测精度。

收稿日期:2018-05-13

基金项目:国家自然科学基金(61503255)、航空科学基金(2016ZC54011)和辽宁省自然科学基金(2015020063)资助

作者简介:陈侠(1962—),沈阳航空航天大学教授,主要从事无人机航迹规划研究。

1 SLFRWNN 模型

TSK 模糊模型相对于 Mamdani 模糊推理系统具备如下优点:对动态输入的改变具有较好的敏捷性,较少的处理时间,较高的精确性和鲁棒性。然而,当传统的 TSK 模糊模型的后件部分被具有大量神经元的 WNN 代替时,TSK 模糊模型对输入的改变所需的反应时间增加了。因此,本文提出一种使用单隐含层递归小波神经网络结构嵌入进 TSK 模糊模型的后件部分,简称 SLFRWNN。网络的后件部分是通过使用具有存储网络过去数据能力的单层神经元构成的。由于小波函数具有良好的时-频两域定位特性,这种结构不仅保持了 TSK 模糊模型的后件部分的简洁性,同时也增加了网络的计算能力和收敛能力。假设有 N_r 个模糊 IF-THEN 规则:

- R_1 : IF x_1 is A_{11} AND x_2 is A_{21} AND...
 $x_{N_{in}}$ is $A_{N_{in}1}$ THEN u_1 is $v_1 = w_1 \cdot \psi_1$,
- R_2 : IF x_1 is A_{12} AND x_2 is A_{22} AND...
 $x_{N_{in}}$ is $A_{N_{in}2}$ THEN u_2 is $v_2 = w_2 \cdot \psi_2$,
- ...
- R_{N_r} : IF x_1 is A_{1N_r} AND x_2 is A_{2N_r} AND...
 $x_{N_{in}}$ is $A_{N_{in}N_r}$ THEN u_{N_r} is $v_{N_r} = w_{N_r} \cdot \psi_{N_r}$ (1)

式中, x_i 是模型的第 i 个输入 ($i = 1 : N_{in}$), A_{ij} 是以模糊隶属度函数 $\mu_{A_{ij}}(x_i)$ ($j = 1 : N_r$) 为特征的语言项。具有 N_{in} 个输入和 N_r 个模糊规则的 SLFRWNN 结构如图 1 所示。




图 1 SLFRWNN 结构

第一层的输入直接传递给第二层。第二层包括模型输入的隶属度函数,每个节点的输出计算为

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

式中, c_{ij} 是第 j 个规则中隶属度函数的中心参数, σ_{ij} 是伸缩参数。第三层每个节点代表一个模糊规则 R , 因此, 第三层节点数等于规则 R_1 到 R_{N_r} 的个数。每个节点输出描述为

$$\mu_j(x) = \prod_i \mu_{A_{ij}}(x), \quad i = 1 : N_{in}, \quad j = 1 : N_r, \quad 0 < \mu_j < 1 \quad (3)$$

生成层的小波神经元产生的结果计算方程式中 Π 代表取小运算。第四层代表模糊规则的后件部分, 是将小波函数作为激活函数的单隐含层网络构成。

通过使用小波变换在多个分辨率等级上捕获有用的信息, 模型的学习能力得到了显著增强。由于选取不同的母小波函数, 则对模型性能产生不同的影响。所以本文通过对比 3 种类型的母小波激活函数, 进行研究分析:

1) Gaussian wavelet:

$$\phi(x) = (x) \cdot \exp\left(-\frac{x^2}{2}\right) \quad (4)$$

2) Mexican Hat wavelet:

$$\phi(x) = (1 - x^2) \cdot \exp\left(-\frac{x^2}{2}\right) \quad (5)$$

3) Morlet wavelet:

$$\phi(x) = \cos(5x) \cdot \exp\left(-\frac{x^2}{2}\right) \quad (6)$$

这些小波函数如图 2 所示。




图 2 Gaussian, Mexican Hat 和 Morlet 简化图

第四层每个小波 ϕ_{ij} 都是根据选定的激活函数的母小波经过伸缩平移变换的形式, 表达式为

$$\phi_{ij} \triangleq \phi_{ij}(z_{ij}(k)) = ((u_{ij}(k) - t_{ij}(k)) / d_{ij}(k)) \quad \forall i = 1 : N_{in}, j = 1 : N_r \quad (7)$$

对于离散时间 k

$$u_{ij}(k) = x_i(k) + \phi_{ij}(k - 1)\theta_{ij}(k),$$

$$i = 1 : N_{in}, j = 1 : N_r \quad (8)$$

式中, t_{ij} 和 d_{ij} 分别代表小波函数的平移系数和伸缩系数; θ_{ij} 是递归回环的权重, 称为储备系数。下脚标 ij 表示第 j 个规则对应的第 i 个输入。

$$\psi_j(z_{ij}) = \prod_i \phi(z_{ij}) = \prod_i \phi_{ij}((u_{ij} - t_{ij})/d_{ij})$$

$$\forall i = 1 : N_{in}, j = 1 : N_r \quad (9)$$

第四层的输出结果为

$$v_j(k) = w_j \cdot \psi_j, j = 1 : N_r \quad (10)$$

式中, w_j 是生成层和输出层之间的连接权值。第五层每个节点的输出等于第四层的输出乘第三层节点的输出。这一层的输出表达式为

$$u_j(x) = \hat{\mu}_j(x) \cdot v_j, j = 1 : N_r \quad (11)$$

式中

$$\hat{\mu}_j(x) = \mu_j(x) / \sum_{j=1}^{N_r} \mu_j(x) \quad (12)$$

模糊规则后件部分输出由公式 (10) 计算得到。最终, 第五层输出层的总输出结果是每个规则产生结果的累加和, 计算公式为

$$u(k) = \sum_{j=1}^{N_r} \hat{\mu}_j(x) \cdot v_j = \sum_{j=1}^{N_r} u_j \quad (13)$$

式中, $u(k)$ 是由所提出的 6 个参数 ($c_{ij}, \sigma_{ij}, w_j, \theta_{ij}, t_{ij}, d_{ij}$) 构成的模型输出。网络设计的目的是确定这些参数的最优值。

2 GA 原理

神经网络的收敛速率取决于对被优化参数初始值的选取, 因此, 本文应用基于 GA 的方法初始化 SLFRWNN。在处理连续搜索空间时, 真实编码的遗传算法具有优于二进制表达的优势, 因此, 运用基于真实编码的遗传算法优化技术寻找网络参数的最优解。在网络初始化过程中, 前件隶属度函数的中心参数 c_{ij} 和伸缩参数 σ_{ij} , 小波函数的转换和伸缩系数 t_{ij} 和 d_{ij} , 存储系数 θ_{ij} , 后件部分的权重 w_j 是需要被优化的。假设有 N_s 个样本 ($x(1), x(2), \dots, x(k), \dots, x(N_s)$), SLFRWNN 初始化取决于期望的输出 $u^d(k)$ 和网络输出 $u(k)$ 的误差的最小值。因此, 第 k 个样本中第 q 个染色体的适应度函数为

$$J^q = \sum_{k=1}^{N_s} (u^d(k) - u^q(k))^2 \quad (14)$$

式中, $u^q(k)$ 是对应于第 q 个染色体的网络输出值,

其表达式为

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

$$\sum_{j=1}^{N_r} v_j^q \cdot \frac{\prod_i \exp\left(-\frac{(x_i(k) - c_{ij}^q)^2}{(\sigma_{ij}^q)^2}\right)}{\sum_{j=1}^{N_r} \left[\prod_i \exp\left(-\frac{(x_i(k) - c_{ij}^q)^2}{(\sigma_{ij}^q)^2}\right) \right]}$$

$$\forall i = 1 : N_{in}, j = 1 : N_r \quad (15)$$

式中

$$v_j^q = w_j \cdot \psi_j =$$

$$w_j \cdot \left[\prod_{i=1}^{N_{in}} \left(\frac{(u_{ij} - t_{ij}^q)}{d_{ij}^q} \right) \cdot \exp\left(-0.5 \left(\frac{(u_{ij} - t_{ij}^q)}{d_{ij}^q} \right)^2 \right) \right]$$

$$(16)$$

所以, 第 q 个染色体表示为

$$U^q = [c_{ij}^q \quad \sigma_{ij}^q \quad t_{ij}^q \quad d_{ij}^q \quad \theta_{ij}^q \quad w_j^q]$$

$$\forall i = 1 : N_{in}, j = 1 : N_r \quad (17)$$

式中

$$c^q = [c_{11}^q \quad \dots \quad c_{N_{in}1}^q \quad \dots \quad c_{1N_r}^q \quad \dots \quad c_{N_{in}N_r}^q] \quad (18)$$

$$\sigma^q = [\sigma_{11}^q \quad \dots \quad \sigma_{N_{in}1}^q \quad \dots \quad \sigma_{1N_r}^q \quad \dots \quad \sigma_{N_{in}N_r}^q] \quad (19)$$

$$t^q = [t_{11}^q \quad \dots \quad t_{N_{in}1}^q \quad \dots \quad t_{1N_r}^q \quad \dots \quad t_{N_{in}N_r}^q] \quad (20)$$

$$d^q = [d_{11}^q \quad \dots \quad d_{N_{in}1}^q \quad \dots \quad d_{1N_r}^q \quad \dots \quad d_{N_{in}N_r}^q] \quad (21)$$

$$\theta^q = [\theta_{11}^q \quad \dots \quad \theta_{N_{in}1}^q \quad \dots \quad \theta_{1N_r}^q \quad \dots \quad \theta_{N_{in}N_r}^q] \quad (22)$$

$$w^q = [w_1^q \quad \dots \quad w_{N_r}^q] \quad (23)$$

通过 GA 方法对问题的解空间进行全局搜索, 使得种群中对应最小适应度函数值的最优染色体决定网络参数的初始值。

3 SLFRWNN 反向传播学习算法

本文采用基于微分链式法则的反向传播学习算法调整所有参数。基于单隐层结构改进的网络在实时操作中具有快速训练过程, 并且在此过程中表现出对变化量的快速反应。学习过程的目的是使误差平方和函数最小:

$$E(k) = \frac{1}{2} [(u^d(k) - u(k))^2] = \frac{1}{2} (e(k))^2 \quad (24)$$

u^d 和 u 分别代表离散时间 k 时刻网络的期望输出和实际输出。所有后件部分的参数如 $w_j, t_{ij}, d_{ij}, \theta_{ij} (i = 1 : N_{in}, j = 1 : N_r)$, 使用下面的公式进行调整:

$$\begin{aligned}
w_j(k+1) &= w_j(k) - \gamma^w(k) \frac{\partial E(k)}{\partial w_j(k)} \\
t_{ij}(k+1) &= t_{ij}(k) - \gamma^t(k) \frac{\partial E(k)}{\partial t_{ij}(k)} \\
d_{ij}(k+1) &= d_{ij}(k) - \gamma^d(k) \frac{\partial E(k)}{\partial d_{ij}(k)} \\
\theta_{ij}(k+1) &= \theta_{ij}(k) - \gamma^\theta(k) \frac{\partial E(k)}{\partial \theta_{ij}(k)}
\end{aligned}
\quad (25)$$

$$\forall i = 1 : N_{in}, j = 1 : N_r \quad (25)$$

式中, γ 为学习率并且大于 0, N_{in} 是网络输入变量的个数, N_r 是规则数目。(25) 式中的偏导数变量表示为:

$$\begin{aligned}
\frac{\partial E(k)}{\partial w_j(k)} &= \frac{\partial E(k)}{\partial u(k)} \frac{\partial u(k)}{\partial v_j(k)} \frac{\partial v_j(k)}{\partial w_j(k)} = \\
(u(k) - u^d(k)) \psi_j(z) &\frac{\mu_j(x)}{N_r} \quad (26) \\
&\sum_{j=1}^{N_r} \mu_j(x)
\end{aligned}$$

$$\begin{aligned}
\frac{\partial E(k)}{\partial t_{ij}(k)} &= \frac{\partial E(k)}{\partial u(k)} \frac{\partial u(k)}{\partial v_j(k)} \frac{\partial v_j(k)}{\partial \psi_j(k)} \frac{\partial \psi_j(k)}{\partial z_{ij}(k)} \frac{\partial z_{ij}(k)}{\partial t_{ij}(k)} = \\
(u(k) - u^d(k)) w_j \psi_j &\frac{\mu_j(x)}{N_r} \left(-\frac{1}{d_{ij}} \right) \left(\frac{1}{z_{ij}} - z_{ij} \right) \\
&\sum_{j=1}^{N_r} \mu_j(x) \quad (27)
\end{aligned}$$

$$\begin{aligned}
\frac{\partial E(k)}{\partial d_{ij}(k)} &= \frac{\partial E(k)}{\partial u(k)} \frac{\partial u(k)}{\partial v_j(k)} \frac{\partial v_j(k)}{\partial \psi_j(k)} \\
\frac{\partial \psi_j(k)}{\partial z_{ij}(k)} \frac{\partial z_{ij}(k)}{\partial d_{ij}(k)} &= z_{ij} \frac{\partial E(k)}{\partial t_{ij}(k)} \quad (28)
\end{aligned}$$

$$\begin{aligned}
\frac{\partial E(k)}{\partial \theta_{ij}(k)} &= \frac{\partial E(k)}{\partial u(k)} \frac{\partial u(k)}{\partial v_j(k)} \frac{\partial v_j(k)}{\partial \psi_j(k)} \frac{\partial \psi_j(k)}{\partial z_{ij}(k)} \\
\frac{\partial z_{ij}(k)}{\partial u_{ij}(k)} \frac{\partial u_{ij}(k)}{\partial \theta_{ij}(k)} &= -\phi_{ij}(k-1) \frac{\partial E(k)}{\partial t_{ij}(k)} \quad (29)
\end{aligned}$$

本文选择 Gaussian 小波函数 $\phi(x) = (x) \cdot \exp\left(-\frac{x^2}{2}\right)$ 作为母小波函数。为了增强前件模糊模型部分对输入变量的自适应能力, 本文给出前件部分参数的更新公式如下:

$$\begin{aligned}
\frac{\partial E(k)}{\partial c_{ij}(k)} &= \frac{\partial E(k)}{\partial u(k)} \frac{\partial u(k)}{\partial \rho_j(k)} \frac{\partial \rho_j(k)}{\partial \mu_j(k)} \frac{\partial \mu_j(k)}{\partial c_{ij}(k)} = \\
(u(k) - u^d(k)) v_j &\frac{2\mu_j(x)(x - c_{ij})}{\sigma_{ij}^2 \sum_{j=1}^{N_r} \mu_j(x)} \quad (30)
\end{aligned}$$

$$\begin{aligned}
\frac{\partial E(k)}{\partial \sigma_{ij}(k)} &= \frac{\partial E(k)}{\partial u(k)} \frac{\partial u(k)}{\partial \rho_j(k)} \frac{\partial \rho_j(k)}{\partial \mu_j(k)} \\
\frac{\partial \mu_j(k)}{\partial \sigma_{ij}(k)} &= \frac{(x - c_{ij})}{\sigma_{ij}} \cdot \frac{\partial E(k)}{\partial c_{ij}(k)} \quad (31)
\end{aligned}$$

根据公式(25)~(31)更新参数,使得目标函数 $E(k)$ 达到最小。

4 最优学习率

网络训练过程中,学习率起着至关重要的作用。一方面,如果学习率过小,算法需要很长时间才会收敛,另一方面,学习率取较大的值就会造成训练过程不稳定。为了解决上述问题,本文通过 Lyapunov 稳定性理论得出最优学习率。最优学习率不仅保证学习过程的收敛性,同时也能加速网络的学习过程。网络输入输出表示如下:

$$\mathbf{x}_1 = \begin{bmatrix} \beta^{-1} \cdot (y(k), y(k-1), \dots, y(k-p)) \\ \alpha^{-1} \cdot (u(k), u(k-1), \dots, u(k-q)) \end{bmatrix} \quad (32)$$

$$\hat{y}(k) = \beta f_1(x_1) \quad (33)$$

$\hat{y}(k)$ 是模型的输出 $y(k)$ 的近似值, x_1 是 SLFRWNN 的输入值。 β 和 α 起到规范化的作用,取值范围为 $[-1, 1]$ 。网络后件部分的参数用向量 \mathbf{W} 表示为:

$$\begin{aligned}
\mathbf{W}_j &= [W_j^1, \dots, W_j^l, \dots, W_j^4] = \\
&[w_j, t_{ij}, d_{ij}, \theta_{ij}] \\
\forall i &= 1 : N_{in}, j = 1 : N_r, l = 1 : 4 \quad (34)
\end{aligned}$$

定义 Lyapunov 函数为

$$V(k) = \frac{1}{2} [(y(k) - \hat{y}(k))^2] = \frac{1}{2} (e(k))^2 \quad (35)$$

变化量为

$$\begin{aligned}
\Delta V(k) &= V(k+1) - V(k) = \\
&\frac{1}{2} ((e^2(k+1))^2 - (e(k))^2) \quad (36)
\end{aligned}$$

由下式

$$\begin{aligned}
e(k+1) &= e(k) + \Delta e(k) \Rightarrow e^2(k+1) = \\
&(e(k))^2 + (\Delta e(k))^2 + 2e(k)\Delta e(k)
\end{aligned}$$

可得:

$$\Delta V(k) = \Delta e(k) \left(e(k) + \frac{1}{2} \Delta e(k) \right) \quad (37)$$

误差的改变量为

$$\Delta e(k) = e(k+1) - e(k) \approx \left[\frac{\partial e(k)}{\partial \mathbf{W}(k)} \right]^T$$

$$\Delta W(k) \approx \sum_{j=1}^{N_r} \left\{ \left[\frac{\partial e(k)}{\partial W_j^l(k)} \right]^T \Delta W_j(k) \right\} \quad (38)$$

式中

$$\begin{aligned} \frac{\partial e(k)}{\partial W_j^l(k)} &= - \frac{\partial \hat{y}(k)}{\partial W_j^l(k)} = - \frac{\partial \hat{y}(k)}{\partial v_j} \cdot \frac{\partial v_j}{\partial W_j^l(k)} = \\ &- \beta \frac{\mu_j(x)}{\sum_{j=1}^{N_r} \mu_j(x)} \cdot \frac{\partial v_j}{\partial W_j^l(k)} \end{aligned} \quad (39)$$

由公式(26)可知, $\Delta W_j^l(k)$ 表达式为

$$\begin{aligned} \Delta W_j^l(k) &= - \gamma(k) \frac{\partial E}{\partial W_j^l(k)} = \gamma(k) e(k) \beta \frac{\partial \hat{y}}{\partial W_j^l(k)} = \\ &\gamma(k) e(k) \beta \frac{\mu_j(x)}{\sum_{j=1}^{N_r} \mu_j(x)} \frac{\partial v_j}{\partial W_j^l(k)} \end{aligned} \quad (40)$$

由公式(38)~(40), 可得 $\Delta e(k)$ 为

$$\Delta e(k) = - \frac{\beta^2 \gamma(k) e(k)}{\left(\sum_{j=1}^{N_r} \mu_j(x) \right)^2} \cdot \sum_{j=1}^{N_r} \left((\mu_j(x))^2 \left\| \frac{\partial v_j}{\partial W_j^l(k)} \right\|^2 \right) \quad (41)$$

由公式(37)~(41), 则将 $\Delta V(k)$ 表示为

$$\begin{aligned} \Delta V(k) &= - \frac{\beta^2 \gamma(k) e(k)}{\left(\sum_{j=1}^{N_r} \mu_j(x) \right)^2} \cdot \sum_{j=1}^{N_r} \left((\mu_j(x))^2 \left\| \frac{\partial v_j}{\partial W_j^l(k)} \right\|^2 \right) \cdot \\ &\left(e(k) - \frac{1}{2} \frac{\beta^2 \gamma(k) e(k)}{\left(\sum_{j=1}^{N_r} \mu_j(x) \right)^2} \sum_{j=1}^{N_r} \left((\mu_j(x))^2 \left\| \frac{\partial v_j}{\partial W_j^l(k)} \right\|^2 \right) \right) \end{aligned}$$

化简为

$$\Delta V(k) = - \frac{1}{2} \frac{\eta \beta^2 (e(k))^2}{\left(\sum_{j=1}^{N_r} \mu_j(x) \right)^2} \cdot \sum_{j=1}^{N_r} \left((\mu_j(x))^2 \left\| \frac{\partial v_j}{\partial W_j^l(k)} \right\|^2 \right)$$

式中

$$\begin{aligned} \eta &= \gamma(k) \cdot \\ &\left(2 - \frac{\beta^2 \gamma(k)}{\left(\sum_{j=1}^{N_r} \mu_j(x) \right)^2} \sum_{j=1}^{N_r} \left((\mu_j(x))^2 \left\| \frac{\partial v_j}{\partial W_j^l(k)} \right\|^2 \right) \right) \geq \\ &\gamma(k) \cdot \left(2 - \frac{\beta^2 \gamma(k)}{\left(\sum_{j=1}^{N_r} \mu_j(x) \right)^2} \cdot \right. \\ &\left. \left(\left\{ \max((\mu_j(x))^2) \right\}^2 \left\{ \max \left\| \frac{\partial v_j}{\partial W_j^l(k)} \right\|^2 \right\} \right) \right) \geq 0 \end{aligned}$$

由 Lyapunov 稳定性理论可知, 如果 $\Delta V(k) < 0$, 系统是稳定的。由于 $\forall j=1: N_r$, 则有 $\mu_j(x) \leq 1$, 所以当 $\gamma(k)$ 满足(42) 式时, 则保证网络的收敛性。

$$0 < \gamma(k) < \frac{2}{\frac{\beta^2}{\left(\sum_{j=1}^{N_r} \mu_j(x) \right)^2} \sum_{j=1}^{N_r} \left\{ \max \left\| \frac{\partial v_j}{\partial W_j^l(k)} \right\|^2 \right\}^2} \quad (42)$$

5 空中目标威胁的主要因素

威胁评估系统具有非线性、评估难度大且富含不确定信息等特点。本文采用 G A Miller 的量化原理和归一化对不确定信息进行量化处理^[13], 考虑的影响因素主要有: 对方目标的态势信息、对方目标的作战性能等诸多因素。本文主要考虑了 6 种典型指标, 分别为:

- 1) 目标种类: 分 5 大类: 导弹、直升机、小型目标、大型目标和 TBM。采用 G A Miller 的量化原理对其量化, 得到对应的隶属度 μ 值为 0.1, 0.2, 0.3, 0.4, 0.5;
- 2) 目标干扰能力: 分为很强、强、一般、弱、很弱 5 个等级。对应依次量化为 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。对应其 μ 值分别为 0.9, 0.8, 0.7, 0.6, 0.5, 0.4, 0.3, 0.2, 0.1, 0;
- 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: 其 μ 值按着如下公式进行计算:

$$\mu_1 = \frac{\max\{l_i\} - l_i}{\max\{l_i\} - \min\{l_i\}}$$

- 6) 目标速度: 其 μ 值按着如下公式进行计算:

$$\mu_v = \frac{v_i - \max\{v_i\}}{\max\{v_i\} - \min\{v_i\}}$$

针对上述 6 种指标, 构建基于 SLFRWNN 的威胁评估模型。表 1 为目标威胁数据库^[10] 中的部分数据。从该库中, 随机采用 300 组进行训练, 70 组进行测试。在 SLFRWNN 模型中, 需要对威胁数据进行归一化处理, 范围在 $[0, 1]$ 之间。

表 1 部分目标威胁数据库数据

序号	目标种类	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	大型机	500	130	强	高	360	0.521 2
2	大型机	550	90	中	中	160	0.582 8
3	大型机	650	110	强	低	280	0.646 5
4	大型机	450	80	中	低	300	0.584 3
5	小型机	600	50	中	高	160	0.685 3
6	小型机	650	80	强	中	200	0.742 5
7	小型机	700	120	强	低	320	0.733 6
8	小型机	750	150	中	超低	400	0.754 1
9	直升机	80	20	弱	低	210	0.360 1
10	直升机	83	50	无	中	180	0.350 7
11	直升机	85	100	弱	低	210	0.376 1
12	直升机	88	140	无	超低	320	0.359 2

6 基于 SLFRWNN 的目标威胁评估仿真实验

SLFRWNN 网络一共有 6 层。由于该模型输入、输出是六维和一维,因而对应每层神经元分别为 6—6×5—5—6×5—5—1。第一层是上述 6 种典型指标的 μ 值,第二层隶属度函数层有 6×5 个节点,第三层模糊规则层有 5 个神经元,第四层递归小波变换层有 6×5 个节点,产生层为 5 个节点,第五层输出层为预测目标威胁值。根据大量实验数据计算,设置合适的网络参数,其中迭代次数设置为 500,遗传算法的迭代次数、交叉概率、变异概率分别设置为 30,0.2,0.1。经过遗传算法得到的参数如表 2 和表 3 所示。

表 2 模糊规则前件部分参数

规则	Input1	Input2	Input3	Input4	Input5	Input6
1	$c_{11} = -1.896 9$	$c_{21} = -2.438 5$	$c_{31} = -2.863 1$	$c_{41} = -0.459 4$	$c_{51} = -1.191 9$	$c_{61} = 0.138 5$
	$\sigma_{11} = -1.836 0$	$\sigma_{21} = 1.282 3$	$\sigma_{31} = -2.295 5$	$\sigma_{41} = -1.917 6$	$\sigma_{51} = -1.179 9$	$\sigma_{61} = 1.277 4$
2	$c_{12} = -0.158 4$	$c_{22} = 1.113 3$	$c_{32} = 2.242 1$	$c_{42} = -2.434 5$	$c_{52} = -0.110 8$	$c_{62} = 0.986 3$
	$\sigma_{12} = -1.567 9$	$\sigma_{22} = -1.803 9$	$\sigma_{32} = -1.591 6$	$\sigma_{42} = -2.122 8$	$\sigma_{52} = 1.340 3$	$\sigma_{62} = 1.388 2$
3	$c_{13} = 2.470 9$	$c_{23} = 1.065 8$	$c_{33} = 1.488 1$	$c_{43} = 0.941 9$	$c_{53} = 1.352 0$	$c_{63} = -0.953 2$
	$\sigma_{13} = -1.136 4$	$\sigma_{23} = -2.412 8$	$\sigma_{33} = -0.174 4$	$\sigma_{43} = -2.192 8$	$\sigma_{53} = -0.086 3$	$\sigma_{63} = -1.650 9$
4	$c_{14} = -1.091 3$	$c_{24} = -0.386 5$	$c_{34} = 2.432 3$	$c_{44} = 1.089 5$	$c_{54} = 1.333 8$	$c_{64} = 1.154 6$
	$\sigma_{14} = -2.276 6$	$\sigma_{24} = -0.142 0$	$\sigma_{34} = 1.927 5$	$\sigma_{44} = 1.023 5$	$\sigma_{54} = 1.339 0$	$\sigma_{64} = 0.470 4$
5	$c_{15} = 1.152 0$	$c_{25} = -2.157 5$	$c_{35} = -1.023 7$	$c_{45} = 0.818 2$	$c_{55} = 0.709 0$	$c_{65} = 0.870 6$
	$\sigma_{15} = -0.482 6$	$\sigma_{25} = -2.998 4$	$\sigma_{35} = 1.430 2$	$\sigma_{45} = -1.398 3$	$\sigma_{55} = -0.060 3$	$\sigma_{65} = -1.281 3$

表 3 模糊规则后件部分参数

规则	Rule1	Rule2	Rule3	Rule4	Rule5
	$v_1 w_1 = 1.181 5$	$v_2 w_2 = 0.903 6$	$v_3 w_3 = 1.100 8$	$v_4 w_4 = 0.889 1$	$v_5 w_5 = -1.249 6$
1	$t_{11} = -2.096 1$	$t_{21} = 0.219 4$	$t_{31} = 0.410 7$	$t_{41} = -1.148 6$	$t_{51} = -1.445 9$
	$d_{11} = -0.700 5$	$d_{21} = 2.736 2$	$d_{31} = -1.675 7$	$d_{41} = -1.117 4$	$d_{51} = -2.014 3$
2	$t_{12} = -1.609 0$	$t_{22} = 2.404 6$	$t_{32} = -0.765 7$	$t_{42} = -2.008 7$	$t_{52} = 2.495 5$
	$d_{12} = 1.427 3$	$d_{22} = -0.429 1$	$d_{32} = 1.652 3$	$d_{42} = -0.528 7$	$d_{52} = -2.975 9$
3	$t_{13} = -0.293 3$	$t_{23} = -1.215 8$	$t_{33} = 1.222 9$	$t_{43} = 0.944 9$	$t_{53} = 1.941 7$
	$d_{13} = -1.842 2$	$d_{23} = -1.834 8$	$d_{33} = -1.199 4$	$d_{43} = -1.580 8$	$d_{53} = 0.809 9$
4	$t_{14} = 0.962 1$	$t_{24} = -2.542 5$	$t_{34} = 2.177 5$	$t_{44} = 2.430 2$	$t_{54} = 1.125 4$
	$d_{14} = -2.088 5$	$d_{24} = 2.350 9$	$d_{34} = -2.797 4$	$d_{44} = 0.524 6$	$d_{54} = 0.135 1$
5	$t_{15} = -2.709 8$	$t_{25} = 1.387 1$	$t_{35} = -0.383 6$	$t_{45} = 1.365 7$	$t_{55} = 1.179 4$
	$d_{15} = -0.447 3$	$d_{25} = 1.312 4$	$d_{35} = 0.263 6$	$d_{45} = -1.446 0$	$d_{55} = 1.386 6$
6	$t_{16} = 2.548 3$	$t_{26} = 0.597 9$	$t_{36} = -0.911 0$	$t_{46} = 1.664 3$	$t_{56} = -1.170 4$
	$d_{16} = 0.211 5$	$d_{26} = 2.020 2$	$d_{36} = -1.401 3$	$d_{46} = -0.684 6$	$d_{56} = 0.190 7$

本文分别采用 GA-SLFRWNN、SLFRWNN 和 FNN 3 种建模方法进行仿真,遗传算法适应度变化如图 3 所示,仿真实验对比如图 4 所示,对 3 种网络

模型进行建模并对预测值与真实值进行对比分析,得到如图 5 所示的误差曲线和如图 6 所示的绝对误差百分比曲线。




图 3 遗传算法适应度曲线




图 4 预测输出结果对比




图 5 3 种网络的绝对误差

表 4 3 种模型的仿真结果和误差分析

样本点	测试值	GA-FRWNN	FRWNN	FNN	GA-FRWNN 误差	FRWNN 的误差	FNN 的误差
1	0.868 1	0.746 5	0.760 3	0.706 1	0.121 6	0.107 8	0.162 0
2	0.688 3	0.710 7	0.708 3	0.654 2	0.022 4	0.020 0	0.034 1
3	0.707 4	0.710 6	0.688 1	0.593 5	0.003 2	0.019 3	0.113 9
4	0.686 2	0.649 1	0.672 1	0.713 4	0.037 1	0.014 1	0.027 2
5	0.689 1	0.730 1	0.745 2	0.671 4	0.041 0	0.056 1	0.017 7
6	0.644 7	0.636 6	0.688 4	0.659 9	0.008 1	0.043 7	0.015 2
7	0.678 0	0.677 6	0.676 1	0.606 7	0.000 4	0.001 9	0.071 3
8	0.656 4	0.705 2	0.716 8	0.664 3	0.048 8	0.060 4	0.007 9
9	0.653 9	0.691 9	0.679 1	0.659 9	0.038 0	0.025 2	0.006 0
10	0.688 7	0.685 1	0.691 1	0.711 5	0.003 6	0.002 4	0.022 8




图 6 3 种算法的绝对误差百分比

由图 4 可以清晰地看出,SLFRWNN 模型预测值与实际威胁值的绝对误差比 FNN 的误差小,而通

过 GA 优化的 SLFRWNN 模型预测的结果又优于 SLFRWNN。由此可知,GA-SLFRWNN 模型的预测结果非常理想,绝对误差值较小,而且性能稳定。由表 4 计算可得,基于遗传算法优化模糊递归小波神经网络预测的绝对误差和为 0.324 2,模糊递归小波神经网络的绝对误差和为 0.350 9,而模糊神经网络的绝对误差和为 0.478 1。这说明模糊神经网络对数据的学习能力还是有所欠缺的。仿真结果表明:模糊递归小波神经网络对数据的学习能力强于传统的模糊神经网络,具有更好的收敛效率和精度,而经过遗传算法的优化可以使网络具有更好的学习能力,从而进一步验证了 GA-SLFRWNN 目标威胁评估模型的优越性和准确性。

7 结 论

针对空战中目标威胁评估不确定信息的问题,使用基于模糊递归小波神经网络对目标威胁评估进行建模,并采用 GA 对模型初始参数进行优化选取,

通过 Lyapunov 稳定性理论得出了最优学习率。仿真实验表明:相比于 FNN 和 FRWNN,该算法提高了系统的稳定性,加快了收敛速度,增强了预测精度,可以作为今后空中目标威胁评估的有效方法。

参考文献:

- [1] WANG Y, MIAO X. Intuitionistic Fuzzy Perceiving Methods for Situation and Threat Assessment[C]//International Conference on Fuzzy Systems and Knowledge Discovery Sichuan, 2012: 578-582
- [2] 李闯,端木京顺,雷英杰,等. 基于认知图和直觉模糊推理的态势评估方法[J]. 系统工程与电子技术, 2012, 34(10): 2064-2068
LI Chuang, DUANMU Jingshun, LEI Yingjie, et al. Situation Assessment Based on Cognitive Maps and Intuitionistic Fuzzy Reasoning[J]. Systems Engineering and Electronics, 2012, 34(10): 2064-2068 (in Chinese)
- [3] XU Y, MIU X. Multi-Attribute Decision Making Method for Air Target Threat Evaluation Based on Intuitionistic Fuzzy Sets[J]. Journal of Systems Engineering and Electronics, 2012, 23(6): 891-897
- [4] 夏博龄,贺正洪,雷英杰. 基于直觉模糊推理的威胁评估改进算法[J]. 计算机工程, 2009, 35(16): 195-197
XIA Boling, HE Zhenghong, LEI Yingjie. Improved Algorithm of Threat Assessment Based on Intuitionistic Fuzzy Reasoning [J]. Computer Engineering, 2009, 35(16): 195-197 (in Chinese)
- [5] WANG Y, SUN Y, LI J Y, et al. Air Defense Threat Assessment Based on Dynamic Bayesia Network[C]//International Conference on Systems and Informatics, Yantai, 2012: 721-724
- [6] 刘跃峰,陈哨东,赵振宇,等. 基于 FBNs 的有人机/UCAV 编队对地攻击威胁评估[J]. 系统工程与电子技术, 2012, 34(8): 1635-1639
LIU Yuefeng, CHEN Shaodong, ZHAO Zhenyu, et al. Threat Assessment of Manned/Unmanned Combat Aerial Vehicle Formation Air-to-Ground Attack Based on FBNs[J]. Systems Engineering and Electronics, 2012, 34(8): 1635-1639 (in Chinese)
- [7] 曾守桢,穆志民. 基于 Zhenyuan 积分的直觉模糊多属性决策方法[J]. 控制与工程, 2018, 33(3): 542-548
ZENG Shouzhen, MU Zhimin. Method Based on Zhenyuan Integral for Intuitionistic Fuzzy Multiple Attribute Decision Making [J]. Control and Decision, 2018, 33(3): 542-548 (in Chinese)
- [8] 王宝成,栗飞,陈正. 基于模糊 TOPSIS 法的空袭目标威胁评估[J]. 海军航空工程学院学报, 2012, 27(3): 323-326
WANG Baocheng, LI Fei, CHEN Zheng. Air-Attack Targets Threat Assessment Based on Fuzzy TOPSIS[J]. Journal of Naval Aeronautical and Astronautical University, 2012, 27(3): 323-326 (in Chinese)
- [9] 王晓帆,王宝树. 基于直觉模糊与计划识别的威胁评估方法[J]. 计算机科学, 2010, 37(5): 175-177
WANG Xiaofan, WANG Baoshu. Techniques for Threat Assessment Based on Intuitionistic Fuzzy Theory and Plan Recognition [J]. Computer Science, 2010, 37(5): 175-177 (in Chinese)
- [10] 王改革. 基于智能算法的目标威胁估计[D]. 长春: 中国科学院长春光学精密机械与物理研究所, 2013: 67-71
WANG Gaige. Target Threat Assessment Using Intelligence Algorithms[D]. Changchun: Changchun Institute of Optics, Fine Mechanics and Physics Chinese Academy of Sciences, 2013: 67-71 (in Chinese)
- [11] 罗艳春,郭立红,姜晓莲,等. 基于模糊神经网络的空中目标威胁评估[J]. 微计算机信息, 2007, 23(34): 268-270
LUO Yanchun, GUO Lihong, JIANG Xiaolian, et al. Threat Assessment for Aerial Target Based on Fuzzy Neural Network[J]. Microcomputer Information, 2007, 23(34): 268-270 (in Chinese)
- [12] LAM H K, LAUBER J. Membership-Function-Dependent Stability Analysis of Fuzzy-Model-Based Control Systems Using Fuzzy Lyapunov Functions[J]. Informantion Science, 2013, 232(20): 253-266
- [13] 刘海波,王和平,沈立顶,等. 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 Haibo, WANG Heping, SHEN Liding, et al. Target Threat Assessment Using SAPSO and Grey Neural Network[J]. Journal of Northwestern Polytechnical University, 2016, 34(1): 25-32 (in Chinese)

Assessment of Aerial Target Threat Based on Genetic Algorithm Optimizing Fuzzy Recurrent Wavelet Neural Network

CHEN Xia, LIU Zilong, LIANG Hongli

(School of Automatic, Shenyang University of Aerospace, Shenyang 100136, China)

Abstract: In target threat assessment of air combat, the evaluation system model is usually nonlinear and the assessment which is difficult to obtain also has some uncertain information. In order to effectively solve these problems, the Single-hidden-layer Fuzzy Recurrent Wavelet Neural Network Optimized by Genetic Algorithm (GA-SL-FRWNN) is presented in this paper. In this new method, the influence factors for assessment and the ambiguity of their information are first analyzed. The RWNN are embed in the back part of FNN (fuzzy neural network) for the purpose of enhancing self-learning ability. Then GA is used to optimize the initial parameters of the model and the optimal learning rate based on Lyapunov theory is proposed. The simulation results show that the proposed algorithm improves the stability of the evaluation system, accelerates the convergence speed and enhances the prediction accuracy compared with the FNN and SLFRWNN.

Keywords: target threat assessment; fuzzy neural network; fuzzy recurrent wavelet neural network; genetic algorithm; optimal learning rate