

# 船用雷达目标跟踪的新方法

李永红, 栾秀珍, 李春庚, 裘富祥, 王百锁

(大连海事大学, 大连 116026)

**摘 要:** 本文提出一种由广义小波神经网络实现船用雷达跟踪中航迹外推的自适应新方法. 由 S(sigmoid) 函数构造的尺度函数和小波作为网络中神经元的激励函数, 隐层节点数由小波分解次数和处理信号维数决定, 输出层采用局部连接方式以解决多维信号的不利影响. 理论证明, 广义小波神经网络的鲁棒性在一定条件下优于 BP 网络. 仿真表明, 该方法的在线处理运算量不随所跟踪的运动目标模型的复杂性而增加, 并且对变加速和急转弯运动目标具有较高的跟踪精度.

**关键词:** 雷达; 跟踪; 小波神经网络

**中图分类号:** TN953 **文献标识码:** A **文章编号:** 0372-2112 (2000) 09-0019-04

## A Novel Method of Marine Radar Target Tracking

LI Yong-hong, LUAN Xiu-zhen, LI Chun-geng, QIU Fu-xiang, WANG Bai-suo

(Information Engineering College, Dalian Maritime University, Dalian 116026, China)

**Abstract:** This paper presents a novel adaptive method to predict the next point of target on-line by means of general wavelet neural network. The scaling function and wavelet constructed by the sigmoid function are used as the active function in the network. The number of hidden units is determined by the number of wavelet decomposition and the dimension of input signal. The local connection is used in the output layer to destroy the influence of multi-dimension signal processing. It is proved that the robust property of the wavelet network is better than that of BP network in certain conditions. Simulation shows that the computational cost of this method does not increase with the complexity of the model of moving target. Moreover, the method has the higher tracking accuracy for the moving targets with variable acceleration and quick turn in a corner.

**Key words:** radar; tracking; wavelet neural networks

## 1 引言

在船用雷达的信息处理中, 一阶滤波和二阶滤波是在假定目标做匀速和等加速直线运动的模型条件下实现的. 在高斯白噪声条件下, 可以证明, 卡尔曼滤波和预测方法是最佳的. Kalman 滤波和预测方法对匀速直线运动目标是最佳的. Sudano 等在利用二阶滤波和改进机动跟踪方面做了大量的工作<sup>[2,3]</sup>. Blom 和 Bar-Shalom 提出的 IMM 算法, 在兼顾机动和非机动目标的跟踪上取得了一定进展, 但是其实时性较差, 且运算量较大. 目前, 在船用雷达 ARPA 滤波系统中, 一般选择多组参数或自适应一阶滤波, 以提高目标跟踪性能.

Hecht-Nielsen 等学者证明了多层前馈神经网络 (MFNN) 能以一定精度逼近任意复杂的非线性函数, 其运算量不随所逼近函数的复杂性而增加, 且能处理非平稳随机信号的滤波问题, 这为 MFNN 用于船用雷达目标数据的滤波处理提供了理论基础. 改进的 BP 算法分别在解决收敛速度慢和精度受限等问题上取得了良好的效果<sup>[4~7]</sup>. 将 MFNN 与小波分解相结

合的小波神经网络自 1992 年 Zhang 首次提出后得到了不断的发展<sup>[8]</sup>. Pati 将 S 函数构成的仿射框架作为激励函数的小波神经网络用于非线性函数的逼近<sup>[9]</sup>, 取得了良好效果. 许多学者采用正交小波基作为 MFNN 隐节点的激励函数, 并分别在小波基选择、隐节点维数确定等方面进行了研究<sup>[10,11]</sup>.

为了获得一种有效的外推方法来适应船用雷达在各种不同情况下的跟踪处理, 尤其是对变加速和急转弯目标的实时跟踪, 本文提出一种优化船用雷达目标跟踪预测系统的新方法, 即采用具有变动量因子的变步长的广义小波神经网络 (GWNN), 将传统的数据串行处理改为并行处理. 为了克服现有小波神经网络构造存在的一些问题, 例如: 小波的选取与信号实时处理的矛盾; 输入/输出信号维数提高对网络隐节点个数的要求; 网络收敛性受输入/输出信号维数的影响, 本文将 S 函数构成的尺度函数和小波共同用于神经网络中, 充分利用了 S 函数对非线性信号的逼近能力, 小波神经网络中用于学习的目标函数的凸性, 以及尺度函数与小波的互补性. 本文构造的 GWNN 用于多维时间序列的在线预测, 具有收敛速度

收稿日期: 1999-06-09; 修回日期: 2000-03-20

基金项目: 交通部重点科技项目基金 (No. 95-06-02-17)

快,鲁棒性好,隐节点数由小波分解次数和处理信号维数决定等特点.

## 2 具有变动量因子的变步长 MFNN 网络训练

MFNN 包括前向网络和误差反向传播两部分,其中前向网络由一个输入层、一个输出层和若干个隐层组成. 设第  $l$  层含有  $N_l$  个神经元,则网络遵循如下方程

$$e^l(t) = W^l(t) \cdot o^{l-1}(t), \quad l=1, \dots, L \quad (1)$$

式中  $e^l(t)$   $R^{N_l}$  是第  $l$  层神经元的净输入矢量,  $W^l(t) = \{w_{ij}^l, i=1, \dots, N_l, j=1, \dots, N_{l-1}\}$   $R^{N_l \times N_{l-1}}$  为第  $l-1$  层与第  $l$  层神经元之间的连接权值矩阵,  $o^{l-1}(t) = \{o_j^{l-1}(t), j=1, \dots, N_{l-1}\}^T$   $R^{N_{l-1}}$  是第  $l-1$  层神经元的输出矢量,其中  $o_j^{l-1}(t) = (e_j^{l-1}(t))$ , 是激励函数. 选择  $t$  时刻  $o^0(t)$  的理想输出矢量  $d(t) = \{d_i(t), i=1, \dots, N_L\}^T$   $R^{N_L}$ .

MFNN 的学习可以看作是一个非线性优化问题. 设  $o^l(t) = r(t, W(t)) = \{r_i(t, W(t)), i=1, \dots, N_L\}^T$   $R^{N_L}$  是网络滤波输出矢量,其中  $W(t) = \{W^l(t), l=1, \dots, L\}$ , 则误差函数  $E$  由下式给出

$$E[W(t)] = \frac{1}{2} \|d(t) - r(t, W(t))\|^2$$

$$= \left\{ \int_0^{T_0} \left[ d_i(t) - r_i(t, W(t)) \right]^2 dt \right\}^{1/2} \rightarrow \min \quad (2)$$

式中  $W(t)$  属于紧集  $S = \{W: \nabla E[W(t)] < 0\}$ . 对式(2)中的  $E[W(t)]$  进行离散化,并对某一权值  $w$ ,由迭代完成  $E$  的最小化. 若  $k$  时刻选择权值空间的下降方向为  $g(k)$ ,则网络权值  $w(k)$  调整为

$$w(k+1) = w(k) + p(k)g(k) \quad (3)$$

$p(k)$  为  $g(k)$  方向上的优化步长,算法的收敛性和复杂性将取决于  $g(k)$  的选择. 如果采用误差函数的一阶模型

$$E(w) = E[w(k)] + \nabla_w E \cdot (w - w(k)) + O(\|w - w(k)\|^2) \quad (4)$$

则  $(k+1)$  时刻权值修正为

$$w(k+1) = w(k) + p(k) \cdot \nabla_w E \quad (5)$$

为了兼顾数据处理中的运算量和收敛速度两个方面,本文基于最小平方准则和误差函数的一阶模型,将优化步长作为目标运动速度和网络处理精度的函数. 另外,在式(5)中加入一个变动量因子  $l_i(k)$  对网络的连接权值进行修正,其修正量取为

$$w_{ij}^l(k+1) = w_{ij}^l(k) - p_i(k) \cdot \nabla_w E + l_i(k) \cdot w_{ij}^l(k) \quad (6)$$

式中,  $l_i(k)$  取<sup>[5]</sup>

$$l_i(k) = \frac{(l_i(k))^2}{(l_i(m))^2} \quad (7)$$

$$l_j(k) = \begin{cases} l_i^{l+1}(k) \cdot w_{ij}^{l+1}(k) \cdot (net_j^l(k)), & l = L \\ d_j - r_j, & l = L \end{cases} \quad (8)$$

$p_i(k)$  是在负梯度方向上的步长. 选择合适的  $p_i(k)$  使得  $E[w(k+1)] \leq E[w(k)] \leq \dots \leq E[w(0)]$ , 此时  $\nabla E[w(k)]$  在  $S = \{w: E(w) \leq E[w(0)]\}$  中便会满足 Lipschitz 条件. 考虑到工程

上的可实现性,我们在船用雷达数据处理中采用的变步长训练算法如下:

步骤 1: 根据输入数据的一阶差分,预置训练好的网络参数  $w_{ij}$ . 取步长  $p_i(0)$  为

$$p_i(0) = A_i(v) = \left\{ \frac{1}{1 + \exp(\frac{v-1}{1})} + \frac{1}{1 + \exp(\frac{v-2}{2})} \right\} \quad (9)$$

其中  $A_i(v)$  是对航速为  $v$  的匀速运动目标跟踪时已训练好的网络步长,且满足  $\max(v) > v_1 > v_2 > 0, v_2 > v_1 > 0, 0 < v_1 < 1$ .

步骤 2: 计算距离误差  $E_R$ , 转到步骤 5.

步骤 3: 按照如下经验公式选择  $p_i(k+1)$ :

$$p_i(k+1) = \begin{cases} A_i(v), & E_R \leq E_1 \text{ 且 } E_R < 0 \\ \alpha_1 \cdot p_i(k), & E_R > E_2 \text{ 且 } E_R < 0, \alpha_1 > 1 \\ p_i(k), & E_1 < E_R < E_2 \text{ 且 } E_R < 0 \\ \alpha_2 \cdot p_i(k), & E_R > 0, 0 < \alpha_2 < 1 \end{cases} \quad (10)$$

式中  $E_1$  和  $E_2$  是由精度决定的误差门限,  $\alpha_1$  和  $\alpha_2$  为调整系数.

步骤 4: 用式(6)更新权值.

步骤 5: 若  $E_R > E_1$ , 转到步骤 3, 否则  $w_{ij}(k)$  便是此时的最佳权值.

## 3 激励函数的选择

Cybenko 已证明,如果  $f(t)$  是一个有界的连续  $S$  函数,那么对于  $\forall f(t) \in L^2(R)$  和  $\epsilon > 0$ , 则有

$$\left\| f(t) - \sum_{j=1}^N a_j(b_j t + c_j) \right\| < \epsilon \quad (11)$$

因此在 MFNN 的激励函数中,除输出层选择线性函数外,其它层通常取  $S$  函数.

设  $S(t) = \tanh(t/2q)$ , ( $q > 0$ ). 用  $S(t)$  的组合所构成的尺度函数  $\phi(t)$  和小波函数  $\psi(t)$  为<sup>[9]</sup>

$$\phi(t) = S(t+d) - S(t-d) \quad (12)$$

$$\psi(t) = \phi(t+p) - \phi(t-p) \quad (13)$$

$f(t)$  可分解成:

$$f(t) = \sum_k c_k \cdot \phi_{M,k} + \sum_{m < M} d_m \cdot \psi_{m,k} \quad (14)$$

比较式(11)和(14)知,若以  $\phi_{M,k}$  和  $\psi_{m,k}$  作为  $\phi(t)$ , 则  $f(t)$  可用 MFNN 来逼近. 当  $a=2, 0 < b \leq 3.5$  时,  $\phi_{m,k} = a^{-m/2} (a^{-m} t - kb)$  构成  $L^2(R)$  中的一个仿射框架. 将  $\{\phi_{m,k}, m=0, 1, \dots, M, k=1, \dots, n\}$  重新排序得  $\{\phi_j(t), j=n+1, \dots, N\}$ , 则 GWNN 第  $l$  层第  $j$  个神经元的激励函数  $\phi_j(t)$  可选为

$$\phi_j(t) = \begin{cases} S(t), & l \leq L-2 \\ \phi_{M,j}(t), & l = L-1, j=1, \dots, n \\ \phi_j(t), & l = L-1, j=n+1, \dots, N_{L-1} \\ t, & l = L \end{cases} \quad (15)$$

由  $\phi_j(t)$  可知,对某一特定长度信号而言,  $m$  和  $k$  将决定第  $L-1$  层神经元的个数,也即 GWNN 隐层节点的个数由小波分解次数  $M$  和输入信号变化范围确定.

## 4 鲁棒性分析

由式(2)的误差函数  $E$  得:

$$\frac{\partial E}{\partial e^k(t)} = \frac{\partial E}{\partial d^k(t)} \cdot \frac{\partial d^k(t)}{\partial e^k(t)} \quad (16)$$

可以证明

$$\frac{\partial E}{\partial e^0(t)} = D_0 \cdot W^1 \cdot D_1 \cdot W^2 \cdots D_{L-1} \cdot W^L \cdot D_L \cdot (d(t) - d^k(t)) \quad (17)$$

$$W^{k+1} = \frac{\partial e^{k+1}(t)}{\partial e^k(t)} \quad (18)$$

$$D_k = \frac{\partial d^k(t)}{\partial e^k(t)} = \text{diag} \left\{ \frac{d}{dt} (e_j^k(t)), j = 1, \dots, N_k \right\}, \quad 0 \leq k \leq L \quad (19)$$

对 BP 网络, 式(19)的范数为

$$\begin{aligned} D_{k-2} &= \left[ \sum_{j=1}^{N_k} \left\| \frac{d}{dt} (e_j^k(t)) \right\|^2 \right]^{1/2} \leq \sqrt{N_k} \max \left| \frac{d}{dt} s(t) \right| \\ &= \sqrt{N_k} \cdot \frac{1}{2q} \end{aligned} \quad (20)$$

而对 GWNN, 式(19)的范数为

$$D_{L-1-2} = \left[ \sum_{j=1}^n \left\| \frac{d}{dt} (e_j^{L-1}(t)) \right\|^2 + \sum_{j=n+1}^{N_{L-1}} \left\| \frac{d}{dt} (e_j^{L-1}(t)) \right\|^2 \right]^{1/2} \quad (21)$$

当  $d = p = 1, 0 < 1/q < 0.9$  时,  $D_{k-2, \text{GWNN}} < D_{k-2, \text{BP}}$ , 得

$$\left\| \frac{\partial E}{\partial e^0(t)} \right\|_{2, \text{GWNN}} < \left\| \frac{\partial E}{\partial e^0(t)} \right\|_{2, \text{BP}} \quad (22)$$

上式说明选择合适的参数  $d$ 、 $p$  和  $q$ , GWNN 的鲁棒性将优于 BP 网络。

## 5 仿真结果

假设天线旋转周期为 22 转/分, 小波  $\psi(x)$  的时域和频域支集分别为  $[x_{\min}, x_{\max}]$  和  $[w_{\min}, w_{\max}]$ , 则对于处在  $[w_0, w_1]$  内的带限信号样本  $d^0(t)$ , 取  $q > a^{q_0}$  使尺度函数  $\phi(x)$  和小波  $\psi(x)$  的频谱覆盖  $d^0(t)$  的频率范围, 其中

$$q_0 = \max \left\{ \text{int} \left[ \frac{\ln(w_1/w_{\max})}{\ln a} \right], \text{int} \left[ \frac{\ln(w_0/w_{\min})}{\ln a} \right] \right\} \quad (23)$$

以目标位置  $(R, \theta)$ , 航速  $v$  和航向  $\alpha$  的四维矢量作为输入  $d^0(t) = [R, \theta, v, \alpha]$ . 设起始位置  $(R, \theta) = (4.6 \text{ km}, 30^\circ)$ ,  $v = 70^\circ$ , 为保证多维信号处理的收敛性, 输出层采用局部连接方式. 将上述具有变动物因子的变步长 GWNN 算法用于船用雷达航迹外推, 其仿真结果如下:

### 5.1 目标无机动转向运动

图 1(a), (b) 分别示出了稳定跟踪时的距离误差和方位误差随目标运动速度的变化. 图 2 和图 3 分别是初始权值在  $[0, 1]$  中取值, 而速度为  $9.26 + 1.03 \sin(2\pi t/1000) \text{ m/s}$  时等步




图 1 稳定跟踪误差随速度的变化.

(a) 距离误差, (b) 方位误差

长和有变动物因子的变步长 BP 算法进行航迹外推仿真迭代的距离误差. 图 4 是在允许误差范围  $[1.852, 9.26] \text{ m}$  和在  $N(0.5, 0.3)$  噪声环境下, 用 GWNN 对运动矢量为  $(v, \alpha) = (9.26 + 1.03 \sin(2\pi t/1000) \text{ m/s}, 70^\circ)$  实现四维时间序列预测的位置、航速和航向误差.




图 2 等步长 BP 算法航迹外推的距离误差

图 3 有变动物因子的变步长 BP 算法航迹外推的距离误差

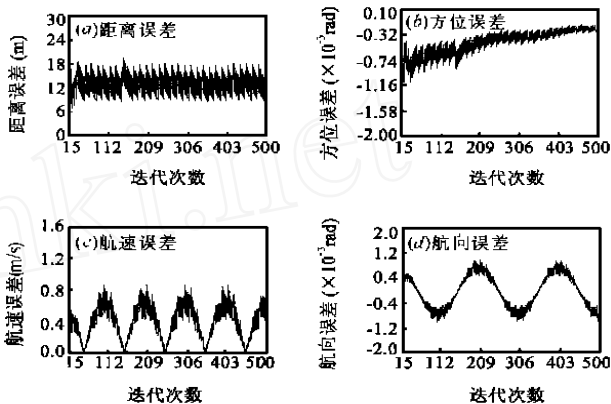


图 4 GWNN 四维信号预测误差

### 5.2 目标急转弯

图 5 表示点迹直线运动在迭代 500 次处转弯半径为 200m, 转向  $50^\circ$  时广义小波神经网络和 BP 神经网络处理的鲁棒性比较.




图 5 急转弯目标的跟踪距离误差

## 6 结束语

在本文的广义小波神经网络中, 神经元的激励函数在输入层选用  $s$  函数, 隐层选用尺度函数和小波. 证明了当参数  $d$ 、 $p$  和  $q$  满足一定条件时, 广义小波神经网络的鲁棒性优于 BP 网络. 本网络隐层节点数由小波分解次数和信号处理维数决定. 仿真表明, 广义小波神经网络用于多维时间序列的在线预测, 具有收敛速度快, 隐节点数可控, 以及鲁棒性好等特点. 本文对于船用雷达航迹外推中的滤波参数的自适应调整提供了新的并行处理方法. 与传统方法相比, 本文方法不受目标运动模型的限制. 由于目标的历史规律在网络的不断学习中已经反映到了各节点的连接权值中, 而算法所需的数据只与前一次的观测值有关, 所以运算量不随所跟踪的目标运动模型的复杂性而增加.

## 参考文献:

- [1] 周宏仁,等. 机动目标跟踪 [M]. 北京:国防工业出版社,1991.
- [2] J.J. Sudano. The tracking filter with a noisy jerk as the maneuver model [J]. IEEE Trans. AES,1993,29(4):578-580.
- [3] Kishore Mehrotra,et al. A jerk model for tracking highly maneuvering targets [J]. IEEE Trans. AES,1997,33(4):1094-1105.
- [4] Youji Iiguni,et al. A real-time learning algorithm for a multilayered neural network based on the extended Kalman filter [J]. IEEE Trans. Signal Processing,1992,40(4):959-966.
- [5] 杨大力,等. 多层前向神经网络中 BP 算法的误调分析及其改进的算法 [J]. 电子学报,1995,23(1):117-120.
- [6] Georg Thimm,et al. The interchangeability of learning rate and gain in backpropagation neural networks [J]. Neural Computation,1996,8:451-460.
- [7] D. George,et al. Effective backpropagation training with variable step-size [J]. Neural Networks,1997,10(1):69-82.
- [8] Qinghua Zhang,Albert Benveniste. Wavelet networks [J]. IEEE Trans. Neural Networks,1992,3(6):889-898.
- [9] Y. C. Pati,et al. Analysis and synthesis of feedforward neural networks using discrete affine wavelet transformations [J]. IEEE Trans. Neural Networks,1993,4(1):73-85.
- [10] 徐晓霞,等. 基于正交最小二乘算法的小波神经网络 [J]. 电子学报,1992,26(10):115-117.
- [11] 黄凤岗,等. 一种自适应的小波神经网络 [J]. 电子学报,1998,26(8):143-145.

## 作者简介:



李永红 1988 年获大连海事大学工学硕士学位,现在该校攻读博士学位. 主要从事雷达数据处理和人工神经网络等方面的研究. 在国内外发表论文 20 余篇.



栾秀珍 1988 年获西安电子科技大学工学硕士学位,现在大连海事大学攻读博士学位. 主要从事微波技术、子波理论和人工神经网络等方面的研究.

(上接第 41 页)

## 参考文献:

- [1] David A. Castanon. Optimal search strategies in dynamic hypothesis testing [J]. IEEE Trans. on SMC,1995,25(7):1130-1138.
- [2] Kastella Keith. Discrimination gain to optimize detection and classification [J]. IEEE Transactions on SMC,1997,27(1):112-116.
- [3] Kastella Keith,Musick. Stan comparison of sensor management strategies for detection and classification [A]. 9th National Symposium on Sensor Fusion [M]. March 1996,Naval Postgraduate School,Monterey, CA.
- [4] Liu Xianxing,Pan Quan,Zhang Hongcai,Dai Guanzhong. Study of algorithm sensor management based on functions of efficiency and waste [J]. Chinese Journal of Aeronautics,2000,13(1).