

基于 Elman 网络结构的惯导平台漂移模型辨识方法

许江涛, 崔乃刚, 穆荣军

(哈尔滨工业大学航天工程系, 黑龙江 哈尔滨 150001)

摘要: 针对惯性导航平台漂移误差高阶非线性动态系统的特点, 利用神经网络的任意逼近能力和自适应抽取系统动态信息的能力, 提出基于 Elman 网络结构的惯性导航平台漂移模型辨识方案。首先建立惯性导航平台漂移误差模型, 并选择了用于网络辨识的输入、输出量。采用动量及可变学习速率算法加速网络的收敛; 在该算法的基础上, 针对网络隐层, 提出的扩展非线性节点函数能更好地改善网络学习效率, 满足系统辨识实时性和精确性的需要。通过测得的惯性导航平台漂移误差数据对网络进行训练, 获得了较为满意的辨识结果。

关键词: 惯导平台; 漂移模型辨识; Elman 网络; 速率算法; 扩展节点函数

中图分类号: V 448

文献标志码: A

DOI: 10.3969/j.issn.1001-506X.2010.07.034

Drift model identification methods for inertial platform based on Elman network

XU Jiang-tao, CUI Nai-gang, MU Rong-jun

(Dept. of Astronautic Engineering, Harbin Inst. of Technology, Harbin 150001, China)

Abstract: The characteristic of the drift error of inertial platform is a high-order nonlinear dynamic system using the neural networks' abilities of universal approximation of differentiable trajectory and capturing system dynamic information, the drift error identifying project of inertial platform is presented based on Elman networks structure. First, the drift error model of inertial platform is established, and after selecting the input and output for network, momentum and alterable speed algorithm is used to speed up the network convergence. On the basis of the algorithm, the extended nonlinear node function in the hidden network not only improves the learning speed of network, but also satisfies the need of accuracy on system identification. Through the drift error data measured on inertial platform the training shows that the scheme achieves a relatively satisfying identification result.

Keywords: platform inertial; drift model identification; Elman network; speed algorithm; extended node function

0 引言

随着惯性技术的发展对惯性导航平台精度要求越来越高, 而受加工水平和制造工艺的限制, 单纯以提高敏感元件的精度来提高整个惯性导航系统精度的代价变得愈发昂贵。相比之下, 从系统角度, 在惯性导航平台各类误差源辨识的基础上进行系统级误差补偿, 则是一种更为经济有效的途径。

传统辨识算法基本原理是通过建立依赖于参数的系统模型, 把辨识问题转化为对模型参数的估计问题^[1]。这类算法能成功地应用于线性系统或本质线性系统, 但对于本质非线性系统, 上述辨识算法已难以付诸应用。具有任意非线性映射能力的多层动态神经网络^[2-4]应用于系统辨识

的优点就是不需要建立实际系统的辨识模型, 它对系统进行辨识是通过直接学习系统的输入输出数据, 学习目的使所要求的误差准则函数达到最小, 归纳出隐含在系统输入输出数据中的系统动态特性。从而归纳出隐含在系统输入输出中的关系。这个关系即为描述系统动态或静态的算子。算子隐含在神经网络内部, 它的表现形式并不重要, 对外界是不可知的。采用神经网络辨识来建立惯性导航平台系统漂移误差的网络模型关键在于训练所需的网络输入输出样本, 及采用能反映系统动态特性且收敛快的网络。满足实际系统误差补偿的精确性和实时性。

惯性导航平台系统漂移误差具有高阶非线性动态特性, 而 Elman 网络^[5] 是多层动态递归网络, 具有很强的非线性逼近能力, 还具有自适应, 自学习, 并行分布式处理的特

点,在导航控制领域中得到了广泛的应用^[5-8]。本文利用 Elman 网络结构对惯性导航平台系统漂移模型进行辨识。网络标准的动态 BP 算法收敛缓慢,而动量及可变的自适应修正权值和阈值,比标准 BP 算法收敛快。本文在变增益系数^[10]的基础上,针对网络隐层,提出扩展非线性节点函数算法,其节点函数随着网络训练的进程而自适应的调整,自适应改变神经元节点函数斜率来改变学习速率,能获得更快的学习速率,可应用于惯性导航系统漂移模型辨识。

1 惯性导航平台漂移误差模型

陀螺仪的漂移及加速度计误差是引起平台漂移的主要因素,它是比力的函数,其漂移模型可描述为^[11]

$$W_o = D_f + D_i a_i + D_s a_s + D_n a_i^2 + D_{oo} a_o^2 + D_{ss} a_s^2 + D_{io} a_i a_o + D_{is} a_i a_s + D_{os} a_o a_s \quad (1)$$

式中, D_f 为与比力无关的常值项; D_i 为与比力成比例的漂移误差系数; D_n 与比力的平方成比例。

加速度计的输出可由下述模型描述

$$A = K_0 + K_1 a_i + K_2 a_i^2 + K_3 a_i^3 + K_{ip} a_i a_p \quad (2)$$

式中, K_0 表示加速度计的零位误差; K_i 表示加速度计的标度因数; K_{ip} 表示加速度计的交叉耦合系数。

对陀螺仪的动态方程进行简化,陀螺的输出模型可表示为

$$\omega_0 = \omega_i + \omega_{md} + \omega_d \quad (3)$$

根据惯性导航平台系统的工作原理,平台相对惯性空间的运动方程为

$$\omega_p = -\omega_0 + \delta\omega_{sevo} \quad (4)$$

由平台角速率与欧拉角速率的投影关系,可得平台欧拉角速率方程

$$\begin{aligned} \dot{\alpha} &= \omega_{xp} \cos \beta + \omega_{zp} \sin \beta \\ \dot{\beta} &= (\omega_{xp} \sin \beta - \omega_{zp} \cos \beta) \sin \alpha / \cos \alpha + \omega_{yp} \\ \dot{\gamma} &= (-\omega_{xp} \sin \beta + \omega_{zp} \cos \beta) / \cos \alpha \end{aligned} \quad (5)$$

式中, ω_{xp} 、 ω_{yp} 和 ω_{zp} 为平台角速率在平台坐标系各轴向的投影; α 、 β 和 γ 为框架欧拉角。

根据以上关系式,组成惯性导航系统平台系统漂移模型^[12]。

2 基于 Elman 网络结构的平台漂移误差模型

2.1 Elman 网络结构

对基本 Elman 网络而言,结构单元用来记忆隐层单元前一时刻的输出值,可认为是一个一步时延算子。这里的前馈连接部分可进行连接权修正,而递归部分则是固定的即不能进行学习修正,从而 Elman 网络仅是部分递归的。其结构示意图如图 1 所示。

设网络的外部输入为 $u(k-1) \in R^r$, 输出为 $y(k) \in R^m$, 记隐层的输入为 $s(k) \in R^n$, 输出为 $x(k) \in R^n$, 则有如下非线性空间表达式

$$\begin{aligned} x(k) &= f(W^1 x_c(k) + W^2 u(k-1)) \\ s(k) &= W^1 x_c(k) + W^2 u(k-1) \\ x_c(k) &= x(k-1), y(k) = g(W^3 x(k)) \end{aligned} \quad (6)$$

式中, W^1 、 W^2 、 W^3 分别为结构单元到隐层、输入层到隐层,以及隐层到输出层的连接权矩阵; $f(\cdot)$ 为隐层单元节点的非线性向量函数,取为 Sigmoid; $g(\cdot)$ 为输出单元节点的线性向量函数。




图 1 Elman 网络结构示意图

2.2 网络结构辨识结构输入输出的选择

惯性导航系统平台漂移模型辨识的最终目的就是为了便于误差补偿,以提高惯性导航系统平台精度。基于神经网络的惯性导航系统平台漂移误差参数辨识是在所选的输入作用下,为保证一定逼近精度,输出逼近于实际测量得到的漂移,可认为此时神经网络的内部结构就反映了所要辨识的参数。在平台漂移误差简化模型中,我们只考虑了和陀螺有关的误差项,包括三个陀螺的所有误差项,一共大约 33 项^[11]。本文研究神经网络拟合惯性导航系统平台漂移模型时,选用的是 $3 \times 8 \times 3$ 的 Elman 网络结构可以充分反映这些误差项。对于加速度的误差参数,除了输出标度因素假设是 1 外,其他误差源都假设是零,即加速度计输出是没有误差的,因为平台漂移误差主要是陀螺漂移产生的,所以选择反映惯性导航系统平台漂移误差的框架欧拉角 α 、 β 、 γ 作为神经网络辨识结构的输出。陀螺输出误差模型与陀螺输入轴、输出轴、转子轴方向的外施加加速度有关,这些加速度是定义在安装在平台上的陀螺坐标系中的,它们是由框架欧拉角表示的平台姿态位置函数。

外施重力加速度激励时,不考虑平台安装误差角,设加速度计的输出无误差,则沿 X、Y、Z 陀螺组件的输入、输出和自选轴的外施加加速度 a_{igj} 、 a_{ogj} 、 a_{sgj} ($j = X, Y, Z$) 可用 3 个加速度计的输出来描述^[11]。

3 网络算法研究与仿真分析

3.1 网络基本算法的仿真分析

$$\begin{aligned} x_c(k) &= x(k-1) = \\ &= f(W^1_{k-1} x_c(k-1) + W^2 u(k-2)) \end{aligned} \quad (7)$$

选用的是 $3 \times 8 \times 3$ 的 Elman 网络结构,考虑如下总体误差目标函数

$$E_p = \sum_{p=1}^N \frac{1}{2} (y_d(k) - y(k))^T (y_d(k) - y(k))$$

式中, p 为网络训练样本对; N 为输出层的节点数; $y_d(k)$ 和 $y(k)$ 分别为输出层节点 k 时刻的期望输出和实际输出。

基本 Elman 网络的动态反向传播学习算法各层间权值变化可归纳如下

$$\begin{aligned} \Delta w_{ij}^3(k) &= \eta \delta_i^0 x_j(k) \\ i &= 1, 2, \dots, m; j = 1, 2, \dots, n \\ \Delta w_{jq}^2(k) &= \eta \delta_j^h u_q(k-1) \\ j &= 1, 2, \dots, n; q = 1, 2, \dots, r \\ \Delta w_{jl}^1(k) &= \eta \sum_{i=1}^m (\delta_i^0 w_{ij}^3) \frac{\partial x_j(k)}{\partial w_{jl}^1} \\ j &= 1, 2, \dots, n; l = 1, 2, \dots, n \\ \frac{\partial x_j(k)}{\partial w_{jl}^1(k)} &= f'_j(\cdot) \left\{ x_i(k-1) + \sum_{i=1}^n w_{ji}^1 \frac{\partial x_i(k-1)}{\partial w_{jl}^1} \right\} \quad (8) \end{aligned}$$

式中

$$\delta_i^0 = (y_{d,i}(k) - y_i(k)) g'_i(\cdot), \delta_j^h = \sum_{i=1}^m (\delta_i^0 w_{ij}^3) f'_j(\cdot)$$

仿真选取 6 个测漂位置,采集 49 980 对数据作为网络输入输出样本对,网络中隐层节点函数为非线性函数 Sigmoid,输出层是线性函数。文中所有仿真均在此条件下获得。

基本算法网络辨识仿真结果见图 2。




图 2 基本算法辨识过程及仿真结果

图 2 中, $W(i, j) (i=1; j=1, 2, 3)$ 分别表示第一个隐层单元节点到输出层 3 节点的连接权值。

通过网络结构辨识后, Y_1, Y_2, Y_3 分别反映平台漂移差的输出框架角 α, β, γ , 为了说明辨识的可行性, 只给出了 Y_1 实际输出拟合量测值的仿真图。为便于不同算法进行比较, 改进算法的仿真算例也选择这些权值、框架角。

由图 2 可看出动态反向传播基本算法在辨识过程中振荡, 最后输出不能逼近量测值, 且收敛慢。对于惯性导航系统平台系统这样的高阶动态系统来说, 多层网络的均方误差性能曲面并不是一个二次函数, 曲面的形状随参数空间

区域的不同而不同, 存在多个局部极小点。算法开始收敛很快, 但训练到达极小点时, 算法容易发散, 导致振荡产生, 则需要降低学习速; 在到达误差曲面的平坦区域时, 收敛较慢, 需要加快学习速度。

3.2 网络改进算法及仿真分析

3.2.1 动量及可变的学习速率算法

利用动量及可变的学习速率算法来加快收敛速度。改进后的权值阈值变化公式如下

$$\begin{aligned} \Delta w_{ij}^3(k) &= \gamma \Delta w_{ij}^3(k-1) - (1-\gamma) \eta \delta_i^0 x_j(k) \\ \Delta w_{jq}^2(k) &= \gamma \Delta w_{jq}^2(k-1) - (1-\gamma) \eta \delta_j^h u_q(k-1) \\ \Delta w_{jl}^1(k) &= \gamma \Delta w_{jl}^1(k-1) - (1-\gamma) \eta \sum_{i=1}^m (\delta_i^0 w_{ij}^3) \frac{\partial x_j(k)}{\partial w_{jl}^1} \\ \Delta b_i^2(k) &= \gamma \Delta b_i^2(k-1) - (1-\gamma) \eta \delta_i^0 \\ \Delta b_j^1(k) &= \gamma \Delta b_j^1(k-1) - (1-\gamma) \eta \delta_j^h \quad (9) \end{aligned}$$

式中, η 表示学习速率因子; γ 是动量系数, 根据网络训练前后均方误差的增长情况来选择 η 和 γ 。

此算法辨识仿真结果如图 3 所示。算法能够获得很好的逼近精度, 收敛速度较快, 但是对于一个实时系统而言, 在实时训练时, 需要快速收敛, 仍需要进一步加快收敛。




图 3 改进算法的辨识过程及仿真结果

3.2.2 基于扩展非线性节点函数改进算法

本文提出一种对神经元节点非线性函数扩展的改进算法, 该算法在训练多层神经网络时, 能够使各神经元节点及整个网络的非线性程度随样本分布自适应地调整, 从而使其收敛性得到改善。

常用的神经元节点非线性函数形式为

$$f(x) = 1.0 / \{1.0 + \exp[-s(k)]\} \quad (10)$$

扩展后的神经元节点非线性函数形式为

$$f(x) = A / \{B + \exp[-Cs(k)]\} \quad (11)$$

式中, A 和 B 为响应参数; C 为增益; 在改进算法中各参数 A 、 B 、 C 、 W 等都将得到自适应的修正。扩展的神经元节点非线性函数在各参数 A 、 B 、 C 、 W 都参与自适应修正时, 可以表现出良好的非线性程度自适应修正的能力, 比起标准的算法而言具有收敛速度快的优点。

各参数变化量如下

$$\begin{aligned} \Delta A_j^2 &= -\eta \frac{\partial E_p}{\partial A_j^2} = -\eta \frac{\partial E_p}{\partial x_j(k)} \frac{\partial x_j(k)}{\partial A_j^2} \\ \Delta B_j^2 &= -\frac{\partial E_p}{\partial B_j^2} = -\frac{\partial E_p}{\partial x_j(k)} \frac{\partial x_j(k)}{\partial B_j^2} \\ \Delta C_j^2 &= -\eta \frac{\partial E_p}{\partial C_j^2} = -\eta \frac{\partial E_p}{\partial x_j(k)} \frac{\partial x_j(k)}{\partial C_j^2} \end{aligned} \quad (12)$$

则隐层各参数 A 、 B 、 C 的修正

$$\begin{aligned} A_j^2(k) &= A_j^2(k-1) - \eta(1-\gamma) \sum_{i=1}^n \delta_i^0 \omega_{ij}^3 \frac{x_j(k)}{A_j^2} + \gamma \Delta A_j^2(k-1) \\ B_j^2(k) &= B_j^2(k-1) + \eta(1-\gamma) \sum_{i=1}^n \delta_i^0 \omega_{ij}^3 \frac{(x_j(k))^2}{A_j^2} + \gamma \Delta B_j^2(k-1) \\ C_j^2(k) &= C_j^2(k-1) - \eta(1-\gamma) \sum_{i=1}^n \delta_i^0 \omega_{ij}^3 s(k) x_j(k) \cdot \left(1 - \frac{B_j^2 x_j(k)}{A_j^2}\right) + \gamma \Delta C_j^2(k-1) \end{aligned} \quad (13)$$

权值、阈值修正仍如式(10)所述。

改进算法仿真曲线如图 4 所示。




图 4 改进算法的辨识过程及仿真结果

由图 4 可知, 神经元节点非线性函数扩展的改进算法能够在保证逼近精度的情况下明显改善收敛速度, 使训练次数明显减少, 但由于多了各参数训练, 所以每次训练的时间要比动量及可变的速率学习算法长。仿真结果表明在达

到均方误差为 6.5×10^{-5} 的逼近精度条件时, 动量及可变速率学习算法比神经元节点非线性函数扩展的改进算法慢。

4 结 论

(1) 动态 Elman 网络用于惯性导航系统平台漂移辨识是可行的, 而且这种结构辨识的精度能满足系统要求。

(2) 由仿真结果知, 网络基本算法用于惯性导航系统平台漂移辨识效果较差, 而两种改进算法能够得到较满意的情况, 尤其是自适应调整参数的扩展神经元节点函数算法在满足精度条件下, 收敛速度比动量及可变速率算法收敛性快近四分之一。

(3) 辨识好的系统为后继飞行器智能自适应控制器设计提供实时可靠的数据。

参考文献:

- [1] 唐江河, 傅振宪, 余贞宇, 等. 线振动条件下惯导平台参数辨识的实现[J]. 航空学报, 2009, 30(6): 1077 - 1083.
- [2] Becerikli Y, Oysal Y. Modeling and prediction with a class of time delay dynamic neural network[J]. *Applied Soft Computing*, 2007, 7(4): 1164 - 1169.
- [3] Jakubek S, Keuth N. A local neuro-fuzzy network for high dimensional models and optimization engineering[J]. *Applications of Artificial Intelligence*, 2006, 9(6): 705 - 717.
- [4] Pepijn W J, Johansen T A, Sørensen J A, et al. Neural network augmented identification of underwater vehicle models[J]. *Control Engineering Practice*, 2007, 15(6): 715 - 725.
- [5] Raşit Köker. Design and performance of an intelligent predictive controller for a six-degree-of-freedom robot using the Elman network[J]. *Information Sciences*, 2006, 176(22): 1781 - 1799.
- [6] Chiang K W, Huang Y W. An intelligent navigator for seamless INS/GPS integrated land vehicle navigation[J]. *Applied Soft Computing*, 2008, 8(1): 722 - 733.
- [7] Seo I H, Leeghim H, Bang H. Nonlinear momentum transfer control of a gyrostat with a discrete damper using neural network[J]. *Acta Astronautica*, 2008, 62(6 - 7): 357 - 373.
- [8] Li Zhijun, Chen Weidong. Adaptive neural-fuzzy control of uncertain constrained multiple coordinated nonholonomic mobile manipulators[J]. *Engineering Applications of Artificial Intelligence*, 2008, 21(1): 985 - 1000.
- [9] 杨博, 苏小红, 王亚东. 基于注意力模型的混合学习算法[J]. 软件学报, 2005, 6(6): 1073 - 1080.
- [10] Kruschke J K, Movelian J R. Benefits of gain: speeded learning and minimal hidden layers in back-propagation networks. *IEEE Trans. on Systems, Man, and Cybernetics*, 1992, 21(1): 273 - 280.
- [11] Hellings F J. Application of extended kalman filtering to a dynamic laboratory calibration of an inertial navigation system[R]. AD-763718, 1973.
- [12] 傅振宪, 邓正隆, 魏宗康. 惯导平台漂移误差参数估计的方案设计与仿真研究[J]. 中国惯性技术学, 1999, 32(2): 70 - 73.